



TUGAS AKHIR – SS141501

OPTIMASI PARAMETER MODEL *SUPPORT VECTOR REGRESSION* UNTUK PEMODELAN BEBAN LISTRIK DI EMPAT BELAS WILAYAH DI JAWA TIMUR DENGAN MENGGUNAKAN *GENETIC ALGORITHM* DAN *PARTICLE SWARM OPTIMIZATION*

**ADAM SURYA WIJAYA
NRP 1313 100 082**

**Dosen Pembimbing
Irhamah M.Si, Ph.D
Pratnya Paramitha O, S.Si.,M.Si.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



TUGAS AKHIR – SS141501

OPTIMASI PARAMETER MODEL *SUPPORT VECTOR REGRESSION* UNTUK PEMODELAN BEBAN LISTRIK DI EMPAT BELAS WILAYAH DI JAWA TIMUR DENGAN MENGGUNAKAN *GENETIC ALGORITHM* DAN *PARTICLE SWARM OPTIMIZATION*

**ADAM SURYA WIJAYA
NRP 1313 100 082**

**Dosen Pembimbing
Irhamah M.Si, Ph.D
Pratnya Paramitha O, S.Si.,M.Si.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT – SS141501

***OPTIMIZE THE PARAMETER OF SUPPORT
VECTOR REGRESSION TO MODELING THE
ELECTRICITY LOAD AT FOURTEEN REGION IN
EAST JAVA USING GENETIC ALGORITHM AND
PARTICLE SWARM OPTIMIZATION***

**ADAM SURYA WIJAYA
NRP 1313 100 082**

**Supervisor
Irhamah, M.Si, Ph.D
Pratnya Paramitha O, S.Si.,M.Si.**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**

LEMBAR PENGESAHAN

OPTIMASI PARAMETER MODEL SUPPORT VECTOR REGRESSION UNTUK PEMODELAN BEBAN LISTRIK DI EMPAT BELAS WILAYAH DI JAWA TIMUR DENGAN MENGUNAKAN GENETIC ALGORITHM DAN PARTICLE SWARM OPTIMIZATION

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

Adam Surya Wijaya
NRP. 1313 100 082

Disetujui oleh Pembimbing:

Irhamah, M.Si, Ph.D

NIP. 19780406 200112 2 002

Pratnya Paramitha O, S.Si, M.Si

NIP 1300201405001

(Irhamah)

(Pratnya)



SURABAYA, JULI 2017

OPTIMASI PARAMETER MODEL *SUPPORT VECTOR REGRESSION* UNTUK PEMODELAN BEBAN LISTRIK PADA EMPAT BELAS WILAYAH DI JAWA TIMUR DENGAN MENGGUNAKAN *GENETIC ALGORITHM* DAN *PARTICLE SWARM OPTIMIZATION*

Nama Mahasiswa : Adam Surya Wijaya
NRP : 1313 100 082
Jurusan : Statistika FMIPA - ITS
Dosen Pembimbing 1 : Dr. Irhamah, M.Si, Ph.D
Dosen Pembimbing 2 : Pratnya Paramitha O, S.Si, M.Si

Abstrak

Beban listrik merupakan salah satu kebutuhan yang dibutuhkan masyarakat. Hal tersebut diketahui dengan meningkatnya permintaan beban listrik dari tahun ke tahun. Dengan adanya peningkatan beban listrik, PLN perlu melakukan tindakan antisipasi akan adanya peningkatakan tersebut karena kemampuan yang terbatas dalam penyediaan beban listrik. Langkah antisipasi yang dapat dilakukan adalah dengan melakukan peramalan beban jangka pendek. ARIMA merupakan metode peramalan dan memiliki kelemahan terhadap pola nonlinier dan pada penelitian sebelumnya, beban listrik memiliki pola nonlinier. Metode SVR merupakan metode yang memiliki fungsi kernel RBF (Gaussian) yang bisa menangani pola nonlinier. Peramalan akan dilakukan dengan menggunakan lag yang signifikan sebagai input pada SVR. SVR memiliki masalah pada penentuan nilai parameternya sehingga perlu dioptimasi menggunakan GA dan PSO. GA dan PSO merupakan sebuah metode optimasi yang menghasilkan nilai akurasi yang baik dan menghasilkan nilai yang global optimum. Kriteria yang digunakan untuk membandingkan antara kedua optimasi tersebut adalah nilai RMSE dan SMAPE. Dalam penelitian ini diperoleh kesimpulan

bahwa metode optimasi GA merupakan metode terbaik karena menghasilkan ramalan dengan nilai RMSE dan sMAPE lebih rendah.

Kata Kunci : Beban Listrik, Optimasi, Peramalan, SVR-GA, SVR-PSO

OPTIMIZE THE PARAMETER OF SUPPORT VECTOR REGRESSION TO MODELING THE ELECTRICITY LOAD AT FOURTEEN REGION IN EAST JAVA BY USING GENETIC ALGORITHM AND PARTICLE SWARM OPTIMIZATION

Student Name : Adam Surya Wijaya
NRP : 1313 100 082
Department : Statistics
Supervisor 1 : Irhamah, M.Si, Ph.D
Supervisor 2 : Pratnya Paramitha O, S.Si, M.Si

Abstract

Electricity load is one of the needs that society needs. This is known by the increasing demand of electrical load from year to year. With the increase in electricity load, PLN needs to take action to anticipate the increase because of the limited ability to supply electrical load. Anticipation steps that can be done is to do forecasting short-term expenses. ARIMA is a method of forecasting and has a weakness to nonlinear pattern and in previous research, electric load has nonlinear pattern. The SVR method is a method that has the function of the RBF (Gaussian) kernel that can handle nonlinear patterns. Forecasting will be done by using a significant lag as input on the SVR. SVR has problems with determining parameter values so it needs to be optimized using GA and PSO. GA and PSO are optimization method that produces good accuracy value and produces global optimum value. The criteria used to compare between the two optimizations are RMSE and SMAPE values. In this research, it can be concluded that GA optimization method is the best method because it yields forecast with lower RMSE and SMAPE value

Keywords: *Electrical Load, Optimization, Forecasting, SVR-GA, SVR-PSO*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur saya haturkan kepada Tuhan Yesus Kristus. Berkat bimbingan dan kuasa-Nya penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **“Optimasi Parameter Model *Support Vector Regression* untuk Pemodelan Beban Listrik di Setiap Kota dan Kabupaten di Jawa Timur dengan Menggunakan *Genetic Alghorithm* dan *Particle Swarm Optimization*”** dengan lancar.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari banyaknya dukungan yang diberikan berbagai pihak. Oleh karena itu, penulis ingin mengucapkan terima kasih kepada:

1. Bapak Dr. Suhartono selaku Ketua Jurusan Statistika dan Bapak Dr. Sutikno, M.Si selaku Koordinator Program Studi S1 yang telah memberikan fasilitas untuk kelancaran penyelesaian Tugas Akhir.
2. Ibu Irhamah, M.Si, Ph.D dan Ibu Pratnya Paramitha, S.Si, M.Si selaku dosen pembimbing dan Prof. Nur Iriawan dan Ibu Santi Wulan P, M.Si selaku dosen penguji yang dengan sangat sabar telah memberikan bimbingan, saran, dan dukungan selama penyusunan Tugas Akhir.
3. Papi, Mami dan Eva yang selalu memberikan dukungan, kasih saying dan doa yang tidak pernah putus kepada penulis.
4. Siti Mar'atus, Novi Ajeng Salehah, Septo Nainggolan dan Adimas Raka Dumarsema, serta teman-teman dari PB. Arthropoda yang telah membantu serta selalu memberi semangat kepada penulis.

Penulis berharap hasil Tugas Akhir ini dapat bermanfaat bagi kita semua dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan oleh Tuhan Yang Maha Esa. Amin.

Surabaya, Juli 2017

Penulis

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
COVER PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxiii
DAFTAR LAMPIRAN	xxv
BAB I PENDAHULUAN	
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
1.5 Batasan Masalah.....	5
BAB II TINJAUAN PUSTAKA	
2.1 <i>Auto Regresive Integrated Moving Average (ARIMA)</i> ...	7
2.2 <i>Support Vector Regression (SVR)</i>	12
2.3 <i>Genetic Alghorithm (GA)</i>	15
2.4 <i>Particle Swarm Optimization</i>	18
2.5 Kriteriaas Kebaikan Model	20
2.6 Beban Listrik	22
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data	23
3.2 Variabel Penelitian	23
3.3 Langkah Analisis	24
3.4 Diagram Alir.....	27

BAB IV ANALISIS DAN PEMBAHASAN

4.1	Karakteristik Permintaan Beban Listrik di Setiap Kota di Jawa Timur	33
4.2	Peramalan Permintaan Beban Listrik Menggunakan ARIMA	38
4.2.1	Peramalan Permintaan Beban Listrik di Kota Surabaya Menggunakan ARIMA	38
4.2.2	Peramalan Permintaan Beban Listrik di Kota Sidoarjo Menggunakan ARIMA.....	46
4.2.3	Peramalan Permintaan Beban Listrik di Kota Gresik Menggunakan ARIMA	53
4.2.4	Peramalan Permintaan Beban Listrik di Kota Pamekasan Menggunakan ARIMA	58
4.2.5	Peramalan Permintaan Beban Listrik di Kota Pasuruan Menggunakan ARIMA	64
4.2.6	Peramalan Permintaan Beban Listrik di Kota Malang Menggunakan ARIMA.....	69
4.2.7	Peramalan Permintaan Beban Listrik di Kota Jember Menggunakan ARIMA.....	75
4.2.8	Peramalan Permintaan Beban Listrik di Kota Banyuwangi Menggunakan ARIMA.....	79
4.2.9	Peramalan Permintaan Beban Listrik di Kota Situbondo Menggunakan ARIMA.....	85
4.2.10	Peramalan Permintaan Beban Listrik di Kota Mojokerto Menggunakan ARIMA	93
4.2.11	Peramalan Permintaan Beban Listrik di Kota Kediri Menggunakan ARIMA.....	98
4.2.12	Peramalan Permintaan Beban Listrik di Kota Bojonegoro Menggunakan ARIMA	103
4.2.13	Peramalan Permintaan Beban Listrik di Kota Madiun Menggunakan ARIMA.....	108
4.2.14	Peramalan Permintaan Beban Listrik di Kota Ponorogo Menggunakan ARIMA.....	113
4.3	Peramalan Permintaan Beban Listrik Dengan Menggunakan SVR	116

4.3.1	Peramalan Beban Listrik Menggunakan SVR untuk Kota Surabaya	117
4.3.2	Peramalan Beban Listrik Menggunakan SVR untuk Kota Lainnya.....	118
4.4	Optimasi Parameter Model SVR dengan Menggunakan GA	120
4.4.1	Optimasi Parameter Model SVR dengan Menggunakan GA untuk Kota Surabaya	121
4.4.2	Optimasi Parameter Model SVR dengan Menggunakan GA untuk Kota Surabaya	125
4.5	Optimasi Parameter Model SVR dengan Menggunakan PSO	126
4.4.1	Optimasi Parameter Model SVR dengan Menggunakan PSO untuk Kota Surabaya	127
4.4.2	Optimasi Parameter Model SVR dengan Menggunakan PSO untuk Kota Surabaya	129
4.6	Perbandingan Akurasi dari Setiap model Peramalan	130
BAB V KESIMPULAN DAN SARAN		
5.1	Kesimpulan.....	131
5.2	Saran	132
DAFTAR PUSTAKA		133
LAMPIRAN		137
BIODATA PENULIS		141

(Halaman sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 2.1	Ilustrasi Perhitungan Error pada SVR..... 13
Gambar 3.1	Diagram Alir Penelitian 27
Gambar 3.2	Diagram Alir Peramlaan Menggunakan ARIMA 27
Gambar 3.3	Diagram Alir Peramalan Menggunakan SVR 27
Gambar 3.4	Diagram Alir Peramalan dengan Metode SVR-GA 27
Gambar 3.5	Diagram Alir Peramlaan dengan Metode SVR-PSO 27
Gambar 4.1	Karakteristik Beban Listrik Berdasarkan Hari 31
Gambar 4.2	Karakteristik Beban Listrik Tiap Kota Berdasarkan Siang dan Malam..... 32
Gambar 4.3	Karakteristik Rata-Rata Beban Listrik Setiap Bulan 33
Gambar 4.4	<i>Time Series Plot</i> Beban Listrik Kota Surabaya(a)Reguler dan (b)Berdasarkan Hari . 34
Gambar 4.5	Transformasi Box-Cox untuk Kota Surabaya . 35
Gambar 4.6	ACF Plot Beban Listrik Kota Surabaya 36
Gambar 4.7	ACF Plot Beban Listrik Kota Surabaya Setelah <i>Differencing</i> pada Lag ke 14 36
Gambar 4.8	(a) Plot ACF dan (b) Plot PACF Beban Listrik Kota Surabaya Setelah <i>Differencing</i> lag 1 dan 14.. 37
Gambar 4.9	Plot Hasil Ramalan <i>Out-sample</i> Kota Surabaya ... 42
Gambar 4.10	<i>Time Series Plot</i> Beban Listrik Kota Sidoarjo(a)Reguler dan (b)Berdasarkan Hari.. 43
Gambar 4.11	Transformasi <i>Box-cox</i> untuk Kota Sidoarjo (a) Sebelum Transformasi dan (b) Setelah Transformasi 44
Gambar 4.12	Plot ACF Kota Sidoarjo (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14. 44
Gambar 4.13	a) Plot ACF dan (b) Plot PACF Kota Sidoarjo Setelah <i>Differencing</i> 1 dan 14..... 45

Gambar 4.14	Plot Hasil Ramalan <i>Out-sample</i> untuk Kota Sidoarjo	49
Gambar 4.15	<i>Time Series Plot</i> Beban Listrik Kota Gresik (a) Reguler dan (b) Berdasarkan Hari..	50
Gambar 4.16	Transformasi <i>Box-cox</i> untuk Kota Gresik(a) Sebelum Transformasi.....	50
Gambar 4.17	Plot ACF Kota Gresik (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	51
Gambar 4.18	a) Plot ACF dan (b) Plot PACF Kota Sidoarjo Setelah <i>Differencing</i> 1 dan 14.....	52
Gambar 4.19	Plot Hasil Ramalan Outsampel untuk kota Gresik	55
Gambar 4.20	<i>Time Series Plot</i> Beban Listrik Kota Pamekasan (a) Reguler dan (b) Berdasarkan Hari.....	56
Gambar 4.21	Transformasi <i>Box-cox</i> untuk Kota Pamekasan(a) Sebelum Transformasi dan (b) Setelah Transformasi	57
Gambar 4.22	Plot ACF Kota Sidoarjo (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	57
Gambar 4.23	a) Plot ACF dan (b) Plot PACF Kota Sidoarjo Setelah <i>Differencing</i> 1 dan 14.....	58
Gambar 4.24	Plot Hasil Ramalan Outsampel untuk kota Gresik	61
Gambar 4.25	<i>Time Series Plot</i> Beban Listrik Kota Pasuruan(a)Reguler dan (b)Berdasarkan Hari.	62
Gambar 4.26	Transformasi <i>Box-cox</i> untuk Kota Pasuruan (a) Sebelum Transformasi dan (b) Setelah Transformasi	62
Gambar 4.27	Plot ACF Kota Pasuruan (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	63
Gambar 4.28	a) Plot ACF dan (b) Plot PACF Kota Pasuruan Setelah <i>Differencing</i> 1 dan 14	64
Gambar 4.29	Plot Hasil Ramalan Outsampel untuk kota Pasuruan	66

Gambar 4.30	<i>Time Series Plot</i> Beban Listrik Kota Malang (a) Reguler dan (b) Berdasarkan Hari	67
Gambar 4.31	Transformasi <i>Box-cox</i> untuk Kota Malang (a) Sebelum Transformasi dan (b) Setelah Transformasi	68
Gambar 4.32	Plot ACF Kota Malang (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	68
Gambar 4.33	a) Plot ACF dan (b) Plot PACF Kota Malang Setelah <i>Differencing</i> 1 dan 14.....	69
Gambar 4.34	Plot Hasil Ramalan Outsampel untuk kota Malang.....	72
Gambar 4.35	<i>Time Series Plot</i> Beban Listrik Kota Jember (a) Reguler dan (b) Berdasarkan Hari.	72
Gambar 4.36	Transformasi <i>Box-cox</i> untuk Kota Jember (a) Sebelum Transformasi dan (b) Setelah Transformasi	73
Gambar 4.37	Plot ACF Kota Jember (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	74
Gambar 4.38	a) Plot ACF dan (b) Plot PACF Kota Jember Setelah <i>Differencing</i> 1 dan 14.....	74
Gambar 4.39	Plot Hasil Ramalan Outsampel untuk kota Jember	77
Gambar 4.40	<i>Time Series Plot</i> Beban Listrik Kota Banyuwangi (a) Reguler dan (b) Berdasarkan Hari.....	78
Gambar 4.41	Transformasi <i>Box-cox</i> untuk Kota Banyuwangi (a) Sebelum Transformasi dan (b) Setelah Transformasi	78
Gambar 4.42	Plot ACF Kota Banyuwangi (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	79
Gambar 4.43	a) Plot ACF dan (b) Plot PACF Kota Banyuwangi Setelah <i>Differencing</i> 1 dan 14....	80
Gambar 4.44	Plot Hasil Ramalan Outsampel untuk kota Banyuwangi.....	83
Gambar 4.45	<i>Time Series Plot</i> Beban Listrik Kota	

	Situbondo (a) Reguler dan (b) Berdasarkan Hari.....	83
Gambar 4.46	Transformasi <i>Box-cox</i> untuk Kota Situbondo (a) Sebelum Transformasi dan (b) Setelah Transformasi	84
Gambar 4.47	Plot ACF Kota Situbondo (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	85
Gambar 4.48	a) Plot ACF dan (b) Plot PACF Kota Situbondo Setelah <i>Differencing</i> 1 dan 14.....	86
Gambar 4.49	Plot Hasil Ramalan Outsampel untuk kota Situbondo	90
Gambar 4.50	<i>Time Series Plot</i> Beban Listrik Kota Mojokerto (a) Reguler dan (b) Berdasarkan Hari.....	91
Gambar 4.51	Transformasi <i>Box-cox</i> untuk Kota Mojokerto (a) Sebelum Transformasi dan (b) Setelah Transformasi	92
Gambar 4.52	Plot ACF Kota Mojokerto (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	92
Gambar 4.53	a) Plot ACF dan (b) Plot PACF Kota Mojokerto Setelah <i>Differencing</i> 1 dan 14	93
Gambar 4.54	Plot Hasil Ramalan Outsampel untuk kota Mojokerto.....	96
Gambar 4.55	<i>Time Series Plot</i> Beban Listrik Kota Kediri (a) Reguler dan (b) Berdasarkan Hari..	96
Gambar 4.56	Transformasi <i>Box-cox</i> untuk Kota Kediri (a) Sebelum Transformasi dan (b) Setelah Transformasi	97
Gambar 4.57	Plot ACF Kota Kediri (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	97
Gambar 4.58	(a) Plot ACF dan (b) Plot PACF Kota Kediri Setelah <i>Differencing</i> 1 dan 14.....	98
Gambar 4.59	Plot Hasil Ramalan Outsampel untuk kota Kediri.....	101
Gambar 4.60	<i>Time Series Plot</i> Beban Listrik Kota	

	Bojonegoro (a) Reguler dan (b) Berdasarkan Hari.....	101
Gambar 4.61	Transformasi <i>Box-cox</i> untuk Kota Bojonegoro (a) Sebelum Transformasi dan (b) Setelah Transformasi	102
Gambar 4.62	Plot ACF Kota Bojonegoro (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	103
Gambar 4.63	a) Plot ACF dan (b) Plot PACF Kota Bojonegoro Setelah <i>Differencing</i> 1 dan 14	103
Gambar 4.64	Plot Hasil Ramalan Outsampel untuk kota Bojonegoro.....	105
Gambar 4.65	<i>Time Series Plot</i> Beban Listrik Kota Madiun (a) Reguler dan (b) Berdasarkan Hari	106
Gambar 4.66	Transformasi <i>Box-cox</i> untuk Kota Madiun (a) Sebelum Transformasi dan (b) Setelah Transformasi	106
Gambar 4.67	Plot ACF Kota Madiun (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	107
Gambar 4.68	a) Plot ACF dan (b) Plot PACF Kota Madiun Setelah <i>Differencing</i> 1 dan 14.....	108
Gambar 4.68	Plot Hasil Ramalan Outsampel untuk kota Madiun	109
Gambar 4.70	<i>Time Series Plot</i> Beban Listrik Kota Ponorogo (a) Reguler dan (b) Berdasarkan Hari.....	110
Gambar 4.71	Transformasi <i>Box-cox</i> untuk Kota Ponorogo (a) Sebelum Transformasi dan (b) Setelah Transformasi	110
Gambar 4.72	Plot ACF Kota Ponorogo (a) Tanpa <i>Differencing</i> dan (b) Setelah <i>Differencing</i> 14 .	111
Gambar 4.73	a) Plot ACF dan (b) Plot PACF Kota Ponorogo Setelah <i>Differencing</i> 1 dan 14.....	112
Gambar 4.74	Plot Hasil Ramalan Outsampel untuk kota Ponorogo	113
Gambar 4.75	Plot Perbandingan Hasil Ramalan SVR	

	dengan Data Outsampel untuk Kota Surabaya.	116
Gambar 4.76	Ilustrasi Bentuk Kromosom	120
Gambar 4.77	Ilustrasi Pindah Silang pada Kromosom	121
Gambar 4.78	Plot Hasil Ramlaan SVR-GA dengan Data Outsample Untuk Kota Surabaya.....	122
Gambar 4.79	Perbandingan Hasil Ramalan SVR-PSO dengan data Outsample	127

DAFTAR TABEL

	Halaman
Tabel 2.1 Pola Plot ACF dan PACF untuk Model ARIMA.....	9
Tabel 3.1 Struktur Data.....	23
Tabel 4.1 Karakteristik Permintaan Beban Listrik untuk Setiap Kota di Jawa Timur.....	31
Tabel 4.2 Hasil Uji Signifikansi Parameter untuk Model ARIMA Kota Surabaya	39
Tabel 4.3 Pengujian Asumsi <i>White Noise</i> dan Distribusi Normal	41
Tabel 4.4 Hasil Pengujian Asumsi untuk Model ARIMA <i>Outlier</i> kota Surabaya	43
Tabel 4.5 Uji Signifikansi Model ARIMA untuk Kota Sidoarjo.....	47
Tabel 4.6 Uji pada Asumsi <i>White Noise</i> dan Distribusi Normal	49
Tabel 4.7 Pengujian Asumsi ARIMA <i>Outlier</i> Kota Sidoarjo.....	50
Tabel 4.8 Uji Signifikansi Model ARIMA untuk Kota Gresik.....	56
Tabel 4.10 Pengujian Asumsi ARIMA <i>Outlier</i> Kota Gresik...	59
Tabel 4.11 Uji Signifikansi Model ARIMA untuk Kota Pamekasan	62
Tabel 4.12 Pengujian Asumsi ARIMA <i>Outlier</i> Kota Pamekasan	63
Tabel 4.13 Uji Signifikansi Model ARIMA untuk Kota Pasuruan.....	69
Tabel 4.14 Pengujian Asumsi ARIMA <i>Outlier</i> Kota Pasuruan.....	70

Tabel 4.15	Uji Signifikansi Model ARIMA untuk Kota Malang	74
Tabel 4.16	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Malang	75
Tabel 4.17	Uji Signifikansi Model ARIMA untuk Kota Jember.....	79
Tabel 4.18	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Jember.....	80
Tabel 4.19	Uji Signifikansi Model ARIMA untuk Kota Banyuwangi	84
Tabel 4.20	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Banyuwangi	86
Tabel 4.21	Uji Signifikansi Model ARIMA untuk Kota Situbondo	92
Tabel 4.22	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Situbondo.....	94
Tabel 4.23	Uji Signifikansi Model ARIMA untuk Kota Mojokerto	98
Tabel 4.24	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Mojokerto	99
Tabel 4.25	Uji Signifikansi Model ARIMA untuk Kota Kediri	100
Tabel 4.26	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Kediri .	103
Tabel 4.27	Uji Signifikansi Model ARIMA untuk Kota Bojonegoro	104
Tabel 4.28	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Bojonegoro	105
Tabel 4.29	Uji Signifikansi Model ARIMA untuk Kota Madiun.....	113
Tabel 4.30	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Madiun.....	114

Tabel 4.31	Uji Signifikansi Model ARIMA untuk Kota Ponorogo.....	116
Tabel 4.32	Pengujian Asumsi ARIMA <i>Outlier</i> Kota Ponorogo.....	117
Tabel 4.33	P-Value Hasil Uji Terasvirta pada 14 Kota	119
Tabel 4.34	Nilai Kebaikan Model SVR Kota Surabaya	121
Tabel 4.35	Hasil Kebaikan Model SVR untuk Setiap Kota dan Kabupaten	122
Tabel 4.36	Nilai Kebaikan Model SVR-GA Kota Surabaya ...	126
Tabel 4.37	Hasil Kebaikan Model SVR-GA untuk Setiap Kota dan Kabupaten.....	128
Tabel 4.38	Nilai Kebaikan Model SVR-PSO Kota Surabaya .	130
Tabel 4.39	Hasil Kebaikan Model SVR-PSO untuk Setiap Kota dan Kabupaten.....	132
Tabel 4.40	Urutan Metode Berdasarkan Nilai sMAPE dari 14 Kota.....	135

(Halaman Sengaja Dikosongkan)

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Surat Legalitas Data	141
Lampiran 2 <i>Syntax</i> untuk Pemodelan ARIMA	142
Lampiran 3 <i>Syntax</i> untuk Pempdelan SVR	143
Lampiran 4 <i>Syntax</i> untuk Pemodelan SVR-GA	144
Lampiran 5 <i>Syntax</i> untuk Pemodelan SVR-PSO	145
Lampiran 6 <i>Syntax</i> untuk Pengujian Nonlinearitas Terasvirta	146

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Listrik merupakan salah satu hal yang menjadi kebutuhan bagi masyarakat di Indonesia. Sebagai salah satu penyedia listrik, PLN harus mampu memenuhi permintaan dari konsumen untuk berbagai kebutuhan, seperti bisnis, rumah tangga, industri dan lain-lain. Manajer Area Pengaturan Beban (APB) PLN Distribusi Jawa Timur menjelaskan bahwa permintaan listrik dari tahun 2009 terus meningkat hingga tahun 2014 (PLN Distribusi Jawa Timur, 2013). Peningkatan terbesar terjadi pada tahun 2012 dimana peningkatan mencapai 10,89% dalam setahun atau setara dengan 13.171,2 MW. Karena peningkatan permintaan beban listrik yang besar, PLN tidak mampu memenuhi beban listrik dan terpaksa melakukan pemadaman di daerah tertentu. Adanya peningkatan tersebut tentu akan berpengaruh terhadap kemampuan PLN dalam menghadapi besarnya permintaan dari masyarakat. Menurut Manajer Bidang Komunikasi, Hukum dan Administrasi PT PLN Distribusi Jawa Timur, permintaan beban puncak diproyeksikan akan mencapai 5200 MW pada tahun 2016 (Tempo, 2016). Peningkatan tersebut diduga karena adanya peningkatan angka elektrifikasi di Jawa Timur menjadi 90% yang meningkat hingga 2% pada akhir tahun 2015. Kemampuan beban maksimal yang dimiliki PLN di Jawa Timur adalah sebesar 8600 MW dan dikurangi dengan permintaan beban dari wilayah Bali maka PLN hanya memiliki surplus beban listrik sebanyak 2000 MW.

Peningkatan beban listrik juga akan menimbulkan beberapa masalah. Salah satu akibat dari peningkatan permintaan beban listrik, terjadi beberapa masalah pada trafo dan pembangkit.

Menurut Suyitno, Manajer PLN Area Ponorogo, masalah terjadi pada PLTU di daerah Pacitan dan terpaksa melepas trafo di daerah Ngawi dan menyebabkan pemadaman pada daerah yang cukup luas (Kusumaningrum, 2016). Berdasarkan hasil survei direktorat Operasi Jawa dan Bali (PLN Distribusi Jawa Timur, 2013), masalah utama dalam peningkatan layanan PLN adalah frekuensi dan durasi pemadaman. Sebanyak 48,7% dari responden menyarankan PLN untuk mengurangi durasi pemadaman listrik. Pemadaman yang dilakukan juga dapat merugikan masyarakat. Terdapat 2200 industri di area Jawa Timur mengalami krisis listrik. Pemadaman yang dilakukan tersebut dapat menurunkan omset hingga 20% (Handayani, 2014). Selain pada bidang industri, pemadaman ini juga berpengaruh pada bidang pendidikan. Pemadaman terjadi pada saat UNBK sehingga menyebabkan komputer mati dan mengganggu proses ujian tersebut (Radar Madiun, 2016).

PLN juga telah melakukan beberapa upaya untuk memenuhi kebutuhan beban listrik dengan menambahkan gardu-gardu ditempat tertentu. Berdasarkan surat pemberitahuan dari Rayon Mantingan akan terjadi pemadaman dalam rangka pemasangan trafo baru di daerah Ngawi (Adhi, 2015). Pola yang dimiliki dari tiap kota dan kabupaten memiliki karakteristik yang berbeda. Dengan adanya pola yang berbeda memerlukan peramalan dari tiap kota sehingga dapat mempersiapkan kota-kota dengan kebutuhan listrik yang tinggi. Upaya lain yang dapat dilakukan adalah dengan melakukan peramalan kebutuhan beban listrik pada periode mendatang. Pada penelitian sebelumnya pernah dilakukan peramalan tiap 30 menit dengan menggunakan kombinasi antara metode ARIMA (*Auto Regressive Integrated Moving Average*) dan regresi linier antara suhu dan daya listrik (Khair, 2011). Hasil peramalan menggunakan kombinasi ARIMA dan regresi linier mendapatkan hasil yang lebih baik dibandingkan tanpa

menggabungkan antara ARIMA dan regresi linier. Tetapi pada beberapa kasus metode ARIMA memiliki beberapa kelemahan sehingga menghasilkan akurasi yang kurang optimal. ARIMA merupakan metode tradisional dimana untuk mendapatkan model yang cocok dengan menggunakan identifikasi memerlukan pengalaman yang lebih dan ARIMA berdasarkan *backward looking* yang berdasarkan *lag*-nya yang berpengaruh sehingga jika digunakan untuk peramalan jangka panjang akan membentuk garis lurus atau pola linier dan lemah pada peramalan dengan pola yang tidak linier atau memiliki titik belok (Zhai, 2005).

Dalam perkembangan ilmu pengetahuan terdapat metode yang dikembangkan berdasarkan *Artificial Intelligence* (AI) yang sering digunakan. Salah satu metode tersebut adalah *Support Vector Regression* (SVR). Diketahui bahwa SVR memiliki fungsi Radial Basis Function (Gaussian) sebagai fungsi kernelnya yang dapat mengatasi fungsi yang non-linier (Hong & et al, 2011). Pada penelitian lain, SVR pernah dikombinasikan dengan LWR (*Locally Weighted Regression*) dan menghasilkan improvisasi pada nilai akurasi yang telah dihasilkan dari model yang terbentuk dari kedua model tersebut (Ehab, Goulernas, & Wu, 2010). Untuk mendapatkan hasil dari SVR yang optimal diperlukan pemilihan nilai parameter secara hati-hati (Duan, Keerthi, & Poo, 2003) sehingga tidak didapatkan nilai optimum lokal. Genetic Algorithm(GA) merupakan salah satu metode yang dapat digunakan untuk mengoptimasi dan memiliki banyak keunggulan seperti hasil akurasi yang tinggi, hasil yang didapatkan merupakan titik global optimum dan lebih mudah menentukan fungsi objektif. Pada penelitian sebelumnya, GA pernah dikombinasikan dengan Regresi Logistik dan menghasilkan nilai R-Square yang lebih tinggi (Kusumawati, Irhamah, & Soedjono, 2014). Pada penelitian lainnya GA dikombinasikan dengan *Back Propagation Method* yang merupakan metode dari *Artificial Neural Network* merupakan

alat yang baik untuk pembuatan keputusan pada peramalan beban listrik (Gupta & Pradeepta, 2012). Selain GA, terdapat metode optimisasi lain yang menghasilkan banyak hasil yang memuaskan, yaitu *Particle Swarm Optimization* (PSO). Numahaludin (2014) melakukan penelitian dengan melakukan optimasi parameter regresi dengan PSO dan menghasilkan tingkat akurasi yang lebih tinggi dibandingkan tanpa optimasi.

Selain dikombinasikan dengan regresi, terdapat penelitian mengenai peramalan beban listrik dengan menggunakan SVR yang dikombinasikan antara SVR-GA dan SVR-PSO. Nilai peramalan tiap 30 menit dari beban listrik dengan menggunakan kombinasi antara SVR-GA menghasilkan akurasi lebih baik dibandingkan dengan SVR (Paramita & Irhamah, 2012). Selain SVR-GA terdapat kombinasi antara metode SVR-PSO yang juga dilakukan pada beban listrik yang dibandingkan dengan *Artificial Neural Network* (ANN). Nilai akurasi yang dihasilkan dari SVR-PSO memiliki hasil akurasi yang lebih tinggi (Trapsilasiwi & Sutijo, 2011). Pada salah satu penelitian telah dibandingkan antara hasil optimasi pada metode fuzzy C-partition dengan GA dan PSO. Hasil akurasi yang didapatkan antara kedua metode sama besar tetapi waktu yang digunakan mendapatkan waktu yang lebih cepat (Ouarda & Bouamar, 2014).

Oleh sebab itu, pada penelitian ini akan dilakukan perbandingan antara kedua metode optimasi yang ada sehingga didapatkan model peramalan yang baik untuk tiap kota dan kabupaten di Jawa Timur. Metode terbaik ditentukan dengan membandingkan nilai kebaikan model dari hasil peramalan kedua metode tersebut. Nilai kebaikan model yang akan digunakan adalah nilai *Root Mean Square Error* (RMSE) dan *Symetric Mean Absolute Percentage Error* (sMAPE).

1.2 Perumusan Masalah

Sebagai salah satu penyedia jasa listrik di Indonesia PLN memiliki banyak permasalahan yang harus diperbaiki. Dengan meningkatnya angka elektrifikasi di Indonesia, khususnya di Jawa Timur, permintaan beban listrik akan terus meningkat di berbagai wilayah. Peningkatan yang tidak diimbangi dengan kemampuan dari PLN untuk menyediakan beban listrik dapat menyebabkan pemadaman-pemadaman di berbagai wilayah yang dapat merugikan konsumen. Upaya yang telah dilakukan pihak PLN adalah dengan menambahkan beberapa gardu listrik tambahan. Upaya dalam bentuk lain juga telah dilakukan yaitu dengan melakukan peramalan menggunakan ARIMA. ARIMA belum bisa menangkap data dengan pola nonlinier sehingga diperlukan metode lain yang dapat menangkap pola nonlinier tersebut. SVR memiliki fungsi kernel yang dapat digunakan untuk mengatasi pola yang nonlinier tersebut. Fungsi kernel yang digunakan adalah RBF (*Gaussian*). SVR memiliki kelemahan dimana sulit menentukan nilai parameter yang sesuai sehingga digunakan metode GA dan PSO. Setiap kota dan kabupaten di Jawa Timur memiliki pola permintaan beban yang berbeda sehingga perlu dilakukan peramalan pada tiap kota dan kabupaten sehingga dapat dibandingkan antara kedua metode untuk optimasi dalam mendapatkan akurasi yang lebih besar.

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Mendapatkan deskripsi karakteristik dari beban listrik yang terdapat pada tiap kota di Jawa Timur.
2. Mendapatkan model peramalan terbaik untuk setiap kota di Jawa Timur dari model SVR dan ARIMA.

3. Mendapatkan hasil optimasi terbaik untuk model peramalan setiap kota di Jawa Timur dari model SVR-GA dan SVR-PSO

1.4 Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah untuk memberikan informasi tambahan dan saran untuk PT. PLN Jawa Timur terkait dengan penyediaan kebutuhan listrik sehingga dapat mengurangi frekuensi dari pemadaman di setiap kota.

1.5 Batasan Penelitian

Batasan masalah yang perlu diperhatikan dalam penelitian ini adalah sebagai berikut.

1. Pemodelan ARIMA dilakukan pada 9 kota dan 29 kabupaten yang terdapat di Jawa Timur. Jika dalam satu kota terdapat dua atau lebih gardu, maka beban listrik dalam satu kota tersebut akan diakumulasikan dari seluruh gardu di kota tersebut.
2. Peramalan dilakukan untuk setiap kota dan kabupaten yang diasumsikan beban listrik dari tiap kota dan kabupaten tidak berkorelasi satu sama lain dan dianggap PLN selalu bisa memenuhi kebutuhan beban listrik di setiap kabupaten dan kota.
3. *Support Vector* yang digunakan pada metode SVR merupakan lag-lag yang signifikan pada model ARIMA.
4. Fungsi Kernel yang digunakan pada metode SVR adalah RBF (Gaussian) dan parameter yang akan dioptimasi adalah *cost*, *gamma* dan *epsilon*.

BAB II

TINJAUAN PUSTAKA

2.1. *Auto Regresive Integrated Moving Average (ARIMA)*

ARIMA merupakan salah satu metode yang sering digunakan dalam analisis deret waktu. ARIMA tersusun dari dua model utama, yaitu *Auto Regresive* (AR) dan *Moving Average* (AR). Model AR memiliki model umum dengan order p seperti pada persamaan (2.1) dan Model MA memiliki model umum dengan order q seperti pada persamaan (2.2) (Wei, 2006)

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t, t = 1, 2, \dots, T \quad (2.1)$$

dan

$$Y_t = a_t - \theta_1 a_{t-1} + \dots + \theta_q a_{t-q}, t = 1, 2, \dots, T \quad (2.2)$$

dimana nilai a_t merupakan suatu proses yang *white noise*. Pada metode ARIMA terdapat beberapa asumsi yang harus dipenuhi. Asumsi yang pertama stasioneritas dalam ARIMA harus dipenuhi, baik stasioner dalam nilai *mean* dan variansnya. Hal ini disebabkan karena proses identifikasi model ARIMA menggunakan nilai *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF) dimana membutuhkan nilai $E(Y_t) = \mu$ dan $\text{Var}(i) = \sigma^2$ untuk setiap t . Proses menstasionerkan dilakukan pada nilai varians terlebih dahulu dan kemudian pada nilai *mean*. Untuk menstasionerkan nilai varians dapat menggunakan transformasi *box-cox*. Apabila nilai *rounded lambda* melewati nilai satu pada nilai selang kepercayaanya maka sudah dapat dikatakan bahwa proses sudah stasioner dalam varians. Jika belum stasioner dalam varians maka dilakukan transformasi pada nilai Y_t dengan rumus (2.3)

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.3)$$

Setelah dilakukan transformasi perlu dilakukan pengecekan ulang dengan *box-cox*. Jika tetap belum stasioner maka tetap dilakukan transformasi hingga stasioner dalam varians. Jika belum stasioner dalam mean maka dapat dilakukan dengan menggunakan *differencing* pada orde d (Box & Cox, 1964). Jika model telah stasioner dalam *mean* maka model yang terbentuk adalah $ARMA(p,q)$ dan jika belum stasioner dan dilakukan *differencing* maka model yang terbentuk adalah $ARIMA(p,d,q)$. Model umum untuk $ARMA(p,q)$ ditunjukkan pada persamaan (2.4) dan $ARIMA(p,d,q)$ ditunjukkan pada persamaan (2.5)

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.4)$$

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.5)$$

dimana $W_t = (1-B)^d Y_t$, dengan d menyatakan order *differencing*.

Langkah selanjutnya adalah melakukan identifikasi model dengan melihat plot dari ACF dan PACF dari data yang telah stasioner dalam *mean* dan varians untuk penentuan orde ARIMA. ACF merupakan sebuah fungsi dari korelasi antara nilai Y_t dan Y_{t+k} dengan rumus pada persamaan (2.7) dan PACF merupakan sebuah fungsi korelasi yang sudah tidak terpengaruhi dependensi linier dari $Y_{t-1}, Y_{t-2}, \dots, Y_{t-k-1}$ atau $\text{Corr}(Y_t, Y_{t-k} | Y_{t-1}, Y_{t-2}, \dots, Y_{t-k-1})$ seperti pada persamaan (2.6)

$$\hat{\phi}_{k+1,k+1} = \text{corr}(Y_t, Y_{t-k} | Y_{t-1}, \dots, Y_{t-k-1}) = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{\sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.6)$$

$$\begin{aligned}
\hat{\rho}_k &= \text{Corr}(Y_t, Y_{t-k}) \\
&= \frac{\text{Cov}(Y_t, Y_{t-k})}{\sqrt{\text{Var}(Y_t)}\sqrt{\text{Var}(Y_{t-k})}} \\
&= \frac{\sum_{t=k}^T (Y_t - \hat{Y})(Y_{t-k} - \hat{Y})}{\sum_{t=1}^T (Y_t - \hat{Y})^2}
\end{aligned} \tag{2.7}$$

dengan nilai $\hat{\phi}_{k+1,j} = \hat{\phi}_{k,j} - \hat{\phi}_{k+1,k+1}\hat{\phi}_{k,k+1-j}$, $j = 1, 2, \dots, k$. Pola yang dibentuk dari plot ACF dan PACF dapat digunakan untuk mengidentifikasi model ARIMA. Hal tersebut ditampilkan dalam tabel 2.1

Tabel 2.1 Pola Plot ACF dan PACF untuk Model ARIMA

Model	ACF	PACF
AR(p)	Turun cepat (dies down)	Terpotong (cuts off) setelah lag p
MA(q)	Terpotong (cuts off) setelah lag q	Turun cepat (dies down)
ARMA(p, q)	Turun cepat (dies down)	Turun cepat (dies down)
AR(P) ^s	Turun cepat (dies down)	Cut off setelah lag ke P^*s
MA(Q) ^s	Cut off setelah lag ke Q^*s	Turun cepat (dies down)
ARMA(P, Q) ^s	Turun cepat (dies down)	Turun cepat (dies down)

Setelah dilakukan identifikasi pada model, maka akan terdapat beberapa kemungkinan model yang dapat terbentuk. Model-model yang terbentuk akan dievaluasi untuk pemenuhan asumsi yang kedua. Model yang terbentuk harus memiliki parameter yang signifikan. Untuk mendapatkan nilai parameter dapat digunakan estimasi parameter dengan menggunakan *Conditional Least Square* (CLS). Pada penelitian ini akan digunakan metode *Conditional Least Square* sebagai metode

mengestimasi nilai parameter model ARIMA. metode estimasi *least square* meminimumkan persamaan berikut ini.

$$S_c(\phi_1, \phi_2, \dots, \phi_p, \mu) = \sum_{t=p+1}^n \left[(Y_t - \mu) - \dots - \phi_p (Y_{t-p} - \mu) \right]^2 \quad (2.8)$$

Persamaan (2.8) disebut juga fungsi *conditional sum of squares*. Berdasarkan prinsip dari *least squares*, parameter ϕ dan μ diestimasi menggunakan masing-masing nilai yang meminimumkan $S(\phi, \mu)$. Berikut merupakan proses penurunan $\frac{\partial S_c}{\partial \mu} = 0$.

$$\sum_{t=p+1}^n 2 \left[(Y_t - \mu) - \dots - \phi_p (Y_{t-p} - \mu) \right] (-1 + \phi_1 + \dots + \phi_p) = 0 \quad (2.9)$$

Sedemikian hingga nilai untuk estimasi parameter dari model AR(p) sebagai berikut

$$\mu = \frac{\left[\sum_{t=p+1}^n Y_t - \phi_1 \sum_{t=p+1}^n Y_{t-1} - \dots - \phi_p \sum_{t=p+1}^n Y_{t-p} \right]}{(n-p)(1 - \phi_1 - \dots - \phi_p)} \quad (2.10)$$

dan untuk n dengan ukuran besar maka

$$\frac{1}{n-p} \sum_{t=p+1}^n Y_t \approx \frac{1}{n-p} \sum_{t=p+1}^n Y_{t-1} \approx \dots \approx \frac{1}{n-p} \sum_{t=p+1}^n Y_{t-p} \approx \bar{Y}, \quad (2.11)$$

Sehingga didapatkan persamaan lebih sederhana dibawah

$$\hat{\mu} \approx \frac{(\bar{Y} - \phi_1 \bar{Y} - \phi_p \bar{Y} - \dots - \phi_p \bar{Y})}{(1 - \phi_1 - \phi_2 - \dots - \phi_p)} = \bar{Y} \quad (2.12)$$

Selanjutnya, dengan menggunakan *least square* meminimumkan fungsi $S_c(\phi_1, \phi_2, \dots, \phi_p)$ untuk mendapatkan estimasi parameter dari ϕ_i . Adapun estimasi parameter ϕ_1 didapatkan dari $\frac{\partial S_c}{\partial \phi_1} = 0$ yang ditunjukkan oleh persamaan berikut ini.

$$\frac{\partial S_c}{\partial \phi_1} = -2 \sum_{t=p+1}^T \left[(Y_t - \bar{Y}) - \phi_1 (Y_{t-1} - \bar{Y}) - \dots - \phi_p (Y_{t-p} - \bar{Y}) \right] (Y_{t-1} - \bar{Y}) = 0 \quad (2.13)$$

Dari persamaan (2.13) dilakukan penurunan pada setiap nilai koefisien AR ke p. Apabila dituliskan dalam persamaan yang lebih

mudah dengan mensubstitusi nilai $\sum_{t=p+1}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})$ dengan nilai r_1 seperti pada persamaan berikut.

$$r_1 = \phi_1 + \phi_2 r_2 + \dots + \phi_p r_p \quad (2.14)$$

Kemudian dilanjutkan dengan melakukan estimasi untuk parameter $\phi_2, \phi_3, \dots, \phi_p$ dapat dilakukan dengan cara yang sama sedemikian hingga hasil estimasi adalah dengan menyelesaikan persamaan berikut ini.

$$\begin{aligned} r_1 &= \phi_1 + \phi_2 r_2 + \dots + \phi_p r_p \\ r_2 &= \phi_1 r_1 + \phi_2 + \dots + \phi_p r_p \\ r_p &= \phi_1 r_1 + \phi_2 r_2 + \dots + \phi_p \end{aligned} \quad (2.15)$$

Misalkan diketahui model ARMA (1,1)

$$Y_t - \phi_1 Y_{t-1} = a_t - \theta_1 a_{t-1} \quad (2.16)$$

Menghitung a_t maka

$$\begin{aligned} a_t &= Y_t - \phi_1 Y_{t-1} + \theta_1 a_{t-1} \\ a_t &= Y_t - \phi_1 Y_{t-1} + \theta_1 (Y_{t-1} - \phi_1 Y_{t-2} + \theta_1 a_{t-2}) \end{aligned} \quad (2.17)$$

Persamaan (2.17) adalah persamaan yang tidak linier di parameter, sehingga untuk model ARMA maka prosedur estimasi non linier *least square* akan digunakan untuk mengestimasi parameter.

Prosedur non linier *least square* akan dilakukan teknik iterasi, karena model linier adalah kasus khusus dari model non linier. Berikut adalah persamaan utama dari *non linier least square* dengan menggunakan model regresi linier.

$$Y_t = E(Y_t | X_t' s) + a_t, \quad (2.18)$$

dimana $t = 1, 2, \dots, n$ dan a_t 's adalah i.i.d $N(0, \sigma_a^2)$ independen untuk setiap X_{t_i} . Dari persamaan sebelumnya, estimasi least square (linier atau non linier) biasa menggunakan perhitungan dengan teknik iterasi sebagai berikut.

- a. Menetapkan vektor inialisasi yaitu \mathbf{a} kemudian menghitung residual $\mathbf{e} = (\mathbf{Y} - \bar{\mathbf{Y}})$ dan residual dari *sum square*.

$$S(\mathbf{a}) = \mathbf{e}'\mathbf{e} = (\mathbf{y} - \bar{\mathbf{y}})'(\mathbf{y} - \bar{\mathbf{y}}) \quad (2.19)$$

dimana $\mathbf{y} = \mathbf{f}(\mathbf{a})$ adalah vektor prediksi dengan mengganti parameter yang tidak diketahui dengan suatu nilai hasil prediksi. Model $f(\mathbf{X}_t, \alpha)$ didekati dengan persamaan deret taylor orde pertama dengan mengekspansi nilai inisial dari $\tilde{\alpha}$ sebagai berikut.

$$f(\alpha) = f(\tilde{\alpha}) + \bar{\mathbf{X}}_{\tilde{\alpha}}\delta, \quad (2.20)$$

dimana $\delta = (\mathbf{a} - \bar{\mathbf{a}})$ dan $\bar{\mathbf{X}}_{\tilde{\alpha}} = [X_{ij}]$ adalah matriks $n \times p$ yang merupakan turunan partial dari $\tilde{\alpha}$. Kemudian dihitung

$$\delta = (\bar{\mathbf{X}}_{\tilde{\alpha}}' \bar{\mathbf{X}}_{\tilde{\alpha}})^{-1} \bar{\mathbf{X}}_{\tilde{\alpha}}' \mathbf{e} = (\delta_1, \dots, \delta_p), \quad (2.21)$$

Untuk non linier model maka $\bar{\mathbf{X}}_{\tilde{\alpha}}$ akan berubah di setiap iterasi.

- b. Menetapkan estimasi *least square* terbaru

$$\hat{\alpha} = \tilde{\alpha} + \delta \quad (2.22)$$

Dan residual dari *sum square* $S(\hat{\alpha})$. Untuk model non linier langkah b ini hanya akan menghasilkan nilai insial baru untuk iterasi selanjutnya.

Jika diberikan model ARMA (p, q) , maka untuk menyelesaikannya bisa digunakan prosedur non linier *least square* untuk menghitung estimasi *least square* dimana meminimalkan eror dari *sum square* $S_*(\emptyset, \mu, \theta)$ atau $S(\emptyset, \mu, \theta)$. Iterasi akan terus dilakukan sampai kriteria konvergen tercapai. Kriteria konvergen adalah mereduksi relatif dari *sum square*, dimana maksimum selisih nilai parameter dari setiap iterasi kurang dari suatu nilai yang ditetapkan atau jumlah iterasi lebih besar dari nilai yang ditetapkan (Wei, 2006).

2.2. Uji Nonlinearitas

Berdasarkan (Terasvirta, 1994) nonlinier model adalah seperti pada persamaan 2.23

$$y_t = f(w_t, v_t, \theta_1) + g(w_t, v_t, \theta_2)\mu_t \quad (2.23)$$

dimana $g(w_t, v_t, \theta_2) \geq 0$, $w_t = (1, y_{t-1}, \dots, y_{t-p})^t$, $v_t = (\mu_{t-1}, \dots, \mu_{t-q})^t$

dan $\mu_t \sim \text{Normal}(0, \sigma^2)$. Jika fungsi f dapat dituliskan dalam persamaan fungsi linear dari tiap variabelnya

$$f(w_t, v_t, \theta_1) = \theta_{1,1}w_t + \theta_{1,2}v_t \quad (2.24)$$

maka dapat dikatakan bahwa model 2.23 merupakan model yang linear dalam mean dan model lainnya merupakan tergolong dalam model nonlinear. Hipotesis yang dimiliki dari pengujian ini adalah sebagai berikut.

$$H_0 : \theta = 0$$

$$H_1 : \theta \neq 0$$

Pengujian dapat dilakukan dengan langkah sebagai berikut.

1. Melakukan estimasi persamaan 2.25 menggunakan Ordinary Least Square dan mendapatkan nilai residual μ_t . Kemudian

$$\text{menghitung nilai } SSR_0 = \sum_{t=1}^T \mu_t^2$$

$$y_t = \beta w_t + f(w_t, v_t, \theta) + \mu_t \quad (2.25)$$

2. Meregresikan μ_t dengan w_t dan z_t dan menghitung nilai SSR_1 .
3. Menghitung Statistik Uji


$$F(k, T-k-p-1) = \frac{(SSR_0 - SSR_1) / k}{SSR_1 / (T-k-p-1)}$$

2.3. Support Vector Regression (SVR)

SVR merupakan metode yang dikembangkan dari SVM (*Support Vector Machine*). SVR hanya digunakan untuk pemodelan regresi dan *time series*. Konsep ε -insensitive loss

function metode SVM dapat digeneralisasi untuk melakukan pendekatan fungsi yang dikenal dengan SVR (Gunn, 1998). SVM merupakan metode yang menggabungkan metode pada komputasi seperti *hyperplane*, kernel dan konsep lainnya yang dapat meminimalkan kesalahan klasifikasinya (Prasetyo, 2014). SVM merupakan metode yang tergolong dalam *supervised learning*. Awalnya SVM hanya digunakan pada data kategorik dengan kelas +1 dan -1.

SVR menggunakan konsep dari *structural risk minimization*, yaitu mengestimasi suatu fungsi dengan meminimalkan batas dari *generalization error* sehingga dapat mengatasi *overfitting*.



Gambar 2.1 Ilustrasi Perhitungan Error pada SVR

Sebagaimana ditunjukkan oleh Gambar 2.1, nilai *error* dianggap sama dengan 0 jika masih berada di antara 0 dan garis $f(x) + \epsilon$, sedangkan bernilai ξ atau ξ^* apabila berada di luar garis batas toleransi. Semakin sempurna suatu fungsi regresi SVR maka batas deviasinya akan bernilai mendekati 0. Fungsi tersebut dapat dituliskan sebagai berikut:

$$f(x) = \mathbf{w}^T \varphi(x) + b, \quad (2.26)$$

dimana :

- w = vektor pembobot
- $\varphi(x)$ = fungsi transformasi dari x
- b = bias.

Koefisien w dan b pada metode ini berfungsi untuk meminimalkan fungsi risiko sehingga fungsi tersebut menjadi sehalus mungkin dan kapasitasnya dapat terkontrol (regularisasi). Koefisien w dan b tersebut diestimasi dengan cara meminimalkan fungsi risiko (*risk function*) dengan rumus seperti pada persamaan sebagai berikut:

$$R(f(x)) = \frac{c}{T} \sum_{t=1}^T L_t(y_t, f(x_t)) + \frac{1}{2} \|w\|^2, \quad (2.27)$$

dimana

$$L_t(y_t, f(x_t)) = \begin{cases} 0 & ; y_t = f(x_t) \\ |y_t - f(x_t)| - \varepsilon & ; \text{lainnya} \end{cases} \quad (2.28)$$

dengan L_ε merupakan ε - *insensitive loss function* , y_t adalah vektor dari nilai sebenarnya, C dan ε merupakan *hyper-parameter* yang sudah ditentukan nilainya.

Fungsi f diasumsikan dapat mendekati semua titik (x_t, y_t) dengan presisi sebesar ε . Disebut kondisi *feasible* jika semua titik berada dalam rentang $f(x) \pm \varepsilon$, sedangkan kondisi *infeasible* jika ada beberapa titik yang tidak berada rentang $f(x) \pm \varepsilon$. Pada titik-titik *infeasible* tersebut bisa ditambahkan variabel *slack* ξ, ξ^* untuk mengatasi *infeasible constrain*, karena itu optimasi pada persamaan (2.17) dapat ditransformasi ke bentuk berikut:

$$\min \frac{1}{2} \|w\|^2 + \frac{c}{T} \sum_{t=1}^T (\xi_t + \xi_t^*), \quad (2.29)$$

dengan batasan:

$$\begin{aligned} w\varphi(x_t) + b - y_t &\leq \varepsilon + \xi_t^* ; \\ y_t - w\varphi(x_t) - b &\leq \varepsilon + \xi_t \end{aligned} \quad (2.30)$$

dan $\xi, \xi^* \geq 0, t=1, 2, \dots, T$.

Hong(2008) menjelaskan bahwa untuk mengoptimalkan batasan tersebut dapat diselesaikan menggunakan *primal lagrangian* seperti persamaan (2.28).

$$\begin{aligned}
& L(w, b, \xi_t, \xi_t^*, a_t, a_t^*, \beta_t, \beta_t^*) \\
&= \frac{1}{2} \|w\|^2 + c \left(\sum_{t=1}^T (\xi_t + \xi_t^*) \right) - \sum_{t=1}^T \beta_t [w\varphi(x_t) + b - y_t + \varepsilon + \xi_t^*] \\
&\quad - \sum_{t=1}^T \beta_t^* [y_t - w\varphi(x_t) - b + \varepsilon + \xi_t^*] - \sum_{t=1}^T (a_t \xi_t - a_t^* \xi_t^*)
\end{aligned} \tag{2.31}$$

Persamaan (2.28) kemudian diminimalkan pada variabel primal w, b, ξ, ξ^* dan dimaksimalkan dalam bentuk *lagrangian multiplier nonnegative* $\alpha_t, \alpha_t^*, \beta_t, \beta_t^*$ seperti ditampilkan pada persamaan berikut:

$$\frac{\partial L}{\partial w} = w - \sum_{t=1}^T (\beta_t - \beta_t^*) \varphi(x_t) = 0, \tag{2.32}$$

$$\frac{\partial L}{\partial b} = \sum_{t=1}^T (\beta_t - \beta_t^*) = 0, \tag{2.33}$$

$$\frac{\partial L}{\partial \xi} = c - \beta_t - a_t = 0, \tag{2.34}$$

$$\frac{\partial L}{\partial \xi^*} = c - \beta_t^* - a_t^* = 0. \tag{2.35}$$

Kondisi Karush-Kuhn-Tucker diaplikasikan untuk model regresi. *Dual lagrangian* pada persamaan (2.31) didapatkan dengan mensubsitusikan persamaan (2.32), (2.33), (2.34), dan (2.35) ke persamaan (2.36).

$$\begin{aligned}
\partial(\beta_t, \beta_t^*) &= \sum_{t=1}^T y_t (\beta_t - \beta_t^*) - \varepsilon \sum_{t=1}^T (\beta_t - \beta_t^*) \\
&\quad - \frac{1}{2} \sum_{t=1}^T \sum_{j=1}^T (\beta_t - \beta_t^*) (\beta_j - \beta_j^*) K(x_t, x_j)
\end{aligned} \tag{2.36}$$

Batasan pada persamaan (2.33) adalah:

$$\begin{aligned}
& \sum_{t=1}^T (\beta_t - \beta_t^*) = 0 \\
& 0 \leq \beta_t \leq C, t = 1, 2, \dots, T,
\end{aligned} \tag{2.37}$$

$$0 \leq \beta_t^* \leq C, t = 1, 2, \dots, T.$$

Persamaan *dual lagrangian* didapatkan ketika fungsi kernel $K(x_t, x_j) = \varphi(x_t)\varphi(x_j)$. RBF (*Gaussian*) merupakan salah satu dari sekian fungsi kernel yang sering digunakan (Haerdle, Prastyo, & Hafner, 2014)

2.4. *Genetic Algorithm (GA)*

GA merupakan sebuah metode optimasi yang dikembangkan pada tahun 1975 di Universitas Michigan. Prosedur awal yang harus terlebih dahulu diinisialisasi sebelum dilakukan analisis menggunakan genetika algoritma genetika.

1. Menentukan representasi genetik
Bentuk kromosom yang harus ditentukan paling dahulu. Ukuran kromosom ditentukan dengan jumlah parameter yang akan dioptimasi. Kromosom merupakan vektor dengan panjang sejumlah parameter.
2. Menentukan Rumusan Fungsi Fitness
Fungsi fitness merupakan sebuah fungsi yang akan digunakan untuk mengukur sebuah individu (kromosom) akan bertahan hidup. Kromosom dengan nilai fitness semakin optimum maka akan bertahan hidup. Nilai fitness dapat digunakan untuk memilih pencarian orang tua menggunakan fungsi kumulatif dari fitness.
3. Menetapkan Nilai Parameter
Dalam GA terdapat beberapa parameter yang harus diinisiasi di awal.
 - a. Ukuran Populasi
Ukuran populasi yaitu jumlah kromosom yang terdapat dalam suatu populasi. Semakin banyak dan beragamnya kromosom yang ada maka peluang untuk mendapatkan individu yang sempurna akan lebih besar.
 - b. Jumlah Iterasi

Iterasi merupakan pengulangan tahapan dari GA hingga mendapatkan nilai fitness yang ditentukan atau hingga batasan iterasi yang diberikan. Jumlah iterasi yang semakin besar tidak menjamin adanya peningkatan kualitas dari kromosom. Lebih baik dilakukan iterasi hingga nilai fitness mencapai batasan tertentu.

c. Peluang Pindah Silang (P_c)

P_c merupakan peluang sebuah kromosom untuk kawin silang. Semakin besar nilai p_c maka akan semakin besar pula kemungkinan terjadi kawin silang untuk mendapatkan individu baru.

d. Peluang Mutasi

Semakin besar probabilitas mutasi akan memperbesar kemungkinan operasi mutasi suatu kromosom yang akan menghasilkan individu-individu baru.

e. *Elitism*

Probabilitas tersebut menentukan individu-individu yang pantas untuk bertahan dalam generasi mendatang dikarenakan *offspring* yang dihasilkan identik dengan *parent*.

Setelah dilakukan inisialisasi awal maka tahapan selanjutnya adalah tahapan utama dalam GA. GA memiliki 7 tahapan utama yang perlu dilakukan. (Ismail & Irhamah, 2008). Tahapannya adalah sebagai berikut.

1. Definisi

Merupakan tahap dimana didefinisikan variabel yang dianggap sebagai kromosom. Optimasi yang dilakukan pada penelitian ini dilakukan pada model SVR. Kromosom akan terdiri dari tiga sel yang terdiri dari parameter dari fungsi kernelnya (c, γ, ε)

2. Inisialisasi

Tahap ini merupakan dilakukan inisialisasi jumlah populasi sebesar P dari N kromosom yang mengandung solusi. Mutasi yang dilakukan secara random pada kromosom yang terpilih.

3. *Fitness Function*

Fungsi yang digunakan untuk mengevaluasi daya tahan untuk hidup dari sebuah kromosom. Semakin tinggi nilai $f(C_i)$ dari setiap kromosom (C_i) memiliki arti bahwa kromosom tersebut dapat bertahan hidup dan tidak akan punah. *Fitness function* yang akan digunakan dalam penelitian ini adalah nilai RMSE dan sMAPE.

4. Seleksi

Tahap yang dilakukan untuk mendapatkan calon orang tua yang akan dipindah silangkan pada tahapan berikutnya. Metode seleksi yang digunakan merupakan *Roulette Wheel*.

5. Pindah Silang

Memasangkan dua kromosom yang telah terpilih pada tahap sebelumnya dan menukarkan satu sel dari tiga sel antar kromosom tersebut sehingga menghasilkan dua kromosom baru. Kromosom baru yang telah terbentuk akan dihitung nilai $f(C_i)$.

6. Mutasi

Setiap kromosom diberi sebuah bilangan random yang berdistribusi $\text{uniform}(0,1)$. Jika nilai bilangan random yang dimiliki kromosom tersebut bernilai lebih kecil dari nilai p_m maka kromosom tersebut merupakan kromosom yang mengalami mutasi. Mutasi dilakukan dengan mengganti nilai salah satu dari sel dengan sebuah nilai lain.

7. *Replace*

Semua kromosom, hasil pindah silang dan mutasi, yang dimiliki akan dihitung nilai dari *fitness function*-nya. Urutkan kromosom dari nilai *fitness* terbesar hingga terkecil. Ambil N

kromosom dengan nilai *fitness* tertinggi dan anggap sebagai generasi baru.

8. *Test*

Jika *Stopping criteria* telah terpenuhi maka iterasi dapat dihentikan dan jika belum maka akan kembali pada tahap kedua.

2.5. *Particle Swarm Optimization (PSO)*

Eksplorasi adalah sebuah kemampuan dari sebuah algoritma untuk mendapatkan sebuah hasil yang optimum pada setiap daerah yang berbeda-beda (Ghalia, 2008). Diketahui bahwa sebuah kelompok hewan seperti burung, semut, ikan dan lain-lain dapat menemukan sebuah wilayah yang memiliki bahan makanan berdasarkan insting. Insting tersebut merupakan kemampuan untuk mengetahui dua daerah, yaitu *local best* dan *globalbest*. Posisi dari tiap individu akan dipengaruhi dari kecepatan gerak tiap individu. Anggap $x_i(t)$ merupakan posisi dari setiap individu ke- i dalam kurun waktu ke- t dan berubah posisi dengan kecepatan $v_i(t)$. Perubahan posisi dari individu dapat dilihat berdasarkan rumus (2.38)

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (2.38)$$

dimana,

$$v_i(t) = v_i(t-1) + c_1 r_1 (localbest(t) - x_i(t-1)) + c_2 r_2 (globalbest(t) - x_i(t-1)) \quad (2.39)$$

Dengan posisi awal dari tiap individu berdistribusi uniform dengan batas x_{min} dan x_{max} . Setelah iterasi ke- i dilakukan didapatkan dua parameter penting dari j (jumlah individu), yaitu nilai terbaik untuk tiap individu disebut dengan $P_{best}(j)$ sebagai nilai optimum dari fungsi objektif dan nilai kecepatan dari tiap partikel ke j . Untuk melakukan evaluasi pada tiap individu berdasarkan fungsi objektif dinyatakan dengan $f[x_1(i)]$, $f[x_2(i)]$, ..., $f[x_n(i)]$ dan proses iterasi akan berhenti setelah nilai

pada fungsi objektif telah konvergen. Jika tidak didapatkan nilai terbaik karena tidak didapatkan hasil yang konvergen maka dapat dilakukan dengan membatasi jumlah iterasi, berhenti setelah mendapatkan solusi yang dapat diterima, berhenti setelah peningkatan tidak ditemukan, berhenti ketika radius dari tiap individu mendekati nol dan berhenti ketika slope dari fungsi objektif mendekati nol.

Variant of PSO adalah pengembangan dari PSO yang digunakan untuk mengurangi waktu untuk mendapatkan hasil yang konvergen dan meningkatkan kualitas dari hasil optimasi. Berikut merupakan variasi yang biasa dilakukan pada metode PSO.

a. *Velocity Damping*

Velocity damping dilakukan untuk mengontrol atau membatasi kecepatan maksimum dari sebuah individu. Jika sebuah individu mencapai kecepatan yang melebihi dari batas maka kecepatan dari individu tersebut akan diubah pada kecepatan maksimum.

$$v_{ij} = \begin{cases} v'_{ij}(t+1) & ; v_{ij}(t+1) < v_{\max}(J) \\ v_{\max}(J) & ; \text{lainnya} \end{cases} \quad (2.40)$$

b. *Inertia Weight*

Inertia weight merupakan sebuah mekanisme yang dilakukan untuk melakukan kontrol pada eksplorasi yang dilakukan individu. Cara ini juga merupakan salah satu langkah untuk membatasi kecepatan yang dimiliki sebuah individu. Untuk globalbest akan dicari menggunakan fungsi kecepatan sebagai berikut.

$$v_{ij}(t+1) = wv_{ij}(t) + c_1 r_{1j}(t)(y_{ij}(t) - x_{ij}(t)) + c_2 r_{2j}(t)(\hat{y}_j(t) - x_{ij}(t)) \quad (2.41)$$

c. *Constriction Coefficient*

Batasan ini dikembangkan untuk mendapatkan nilai natural dimana mempermudah untuk mendapatkan nilai yang konvergen tanpa membutuhkan *velocity damping*. *Constriction* ini dilakukan untuk dengan merubah fungsi kecepatan sebagai berikut

$$v_{ij}(t+1) = x[v_{ij}(t) + \phi_1(y_{ij}(t) - x_{ij}(t)) + \phi_2(\hat{y}_j(t) - x_{ij}(t))], \quad (2.42)$$

dengan,

$$\begin{aligned} x &= \frac{2k}{2 - \phi - \sqrt{\phi(\phi - 4)}}; \\ \phi &= \phi_1 + \phi_2 \\ \phi &= c_1 r_1 + c_2 r_2 \end{aligned} \quad (2.43)$$

2.6. Kriteria Kebaikan Model

Untuk mengetahui sebuah model merupakan model yang baik dievaluasi dengan menggunakan nilai *Root Mean Square Error* (RMSE) dan *symetric Mean Absolute Percentage Error* (sMAPE). Metode dengan nilai RMSE dan sMAPE paling kecil merupakan metode yang terbaik dari metode lainnya. Nilai RMSE dan sMAPE dihitung dari data *out-sample* dibandingkan dengan hasil ramalan tiap metode.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{t=1}^M e_t^2}. \quad (2.44)$$

$$sMAPE = \frac{100\%}{T} \sum_{t=1}^T \frac{|Y_t - \hat{Y}_t|}{\left(\frac{|Y_t| + |\hat{Y}_t|}{2}\right)}. \quad (2.45)$$

2.7. Beban Listrik

Pada UU No. 30 Tahun 2009 tentang ketenagalistrikan, dijelaskan mengenai tenaga listrik, yaitu suatu bentuk energi sekunder yang dibangkitkan, ditransmisikan dan didistribusikan untuk segala macam keperluan, tetapi tidak meliputi listrik yang dipakai untuk komunikasi, elektronika atau isyarat. Sedangkan Beban listrik dapat diartikan, seperti peralatan yang terkoneksi

dengan sistem daya dan mengkonsumsi energi listrik dan daya hasil keluaran pembangkit. Beban listrik yang digunakan merupakan beban yang didistribusikan dari pihak PLN ke gardu induk di tiap kota dan kabupaten. Satuan yang dimiliki dari beban listrik merupakan MegaWatt (MW). Untuk menghitung beban listrik yang terdapat dalam Gardu Induk dengan rumus dari Daya.

$$P = VI\sqrt{\cos(\pi)} , \quad (2.43)$$

dimana

V = Voltase (Volt)

I = Arus Listrik (Ampere)

$\cos(\pi)$ = Pembobot pada Gardu Induk

(Halaman ini sengaja dikosongkan)

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari PT PLN Distribusi Jawa Timur. Data merupakan permintaan beban listrik dari 14 kota-kabupaten yang ada di Jawa Timur. Beban listrik tersebut dicatat secara harian pada siang (jam 10.00) dan malam (jam 19.00) periode 1 Januari 2016 hingga 28 Februari 2017. Data tersebut dibagi kedalam dua kelompok, *in-sample* dan *out-sample*. Data *in-sample* dari periode Januari 2016 hingga Desember 2016 dan Data *out-sample* dari periode Januari 2017 sampai Februari 2017.

3.2 Variabel Penelitian

Pada penelitian ini variabel yang digunakan adalah beban listrik harian yang dibagi dalam dua waktu siang dan malam pada 14 wilayah di Jawa Timur. Berikut ini variabel dependen dan variabel independen yang digunakan dalam penelitian ini.

Tabel 3.1Struktur Data

Kota/Kabupaten	Bulan	Tanggal	Beban Listrik	Keterangan
Kota / Kabupaten ke <i>i</i>	1	1	$Y_{i,1}$	In-sample

	1	31	$Y_{i,62}$	In-sample
	2	1	$Y_{i,63}$	In-sample

	12	1	$Y_{i,651}$	Out-sample

	12	31	$Y_{i,732}$	Out-sample

1. Variabel Dependen ($Y_{i,t}$) adalah data beban listrik harian pada kota atau kabupaten ke i yang digunakan sebagai target.
2. Variabel Independen (X) adalah data beban listrik harian yang digunakan merupakan lag yang signifikan dari waktu sebelumnya ($Y_{i,t-1}, Y_{i,t-2}, \dots, Y_{i,t-k}$)

3.3 Langkah Analisis


Analisis data dalam penelitian ini dibedakan menurut permasalahan penelitian sebagai berikut.

1. Melakukan deskripsi beban listrik dari tiap kota dan kabupaten di Jawa Timur.
2. Membagi data menjadi dua bagian, yaitu in-sample dan out-sample.
3. Melakukan pemodelan dengan menggunakan metode ARIMA untuk masing-masing kota dan kabupaten di Jawa Timur. Berikut merupakan tahapannya.
 - a. Melakukan identifikasi melalui plot pada data beban listrik tiap kota untuk mendeteksi stasioneritas data.
 - b. Jika data belum stasioner dalam varians, maka perlu dilakukan transformasi dan jika data belum stasioner dalam mean maka perlu dilakukan *differencing*.
 - c. Jika data telah stasioner dalam varians dan mean, maka langkah selanjutnya adalah melakukan pemodelan untuk model ARIMA dengan melihat pola pada plot ACF dan PACF.
 - d. Melakukan estimasi parameter dan pengujian signifikansi parameter.
 - e. Melakukan pengujian proses *white noised* dan distribusi normal pada residual dari model ARIMA yang telah terbentuk. Jika kedua asumsi tidak terpenuhi maka dicari model baru yang memenuhi kedua asumsi tersebut.
 - f. Melakukan peramalan pada data out-sample dan melakukan perhitungan RMSE dan sMAPE.


- g. Mendapatkan model terbaik dengan membandingkan hasil RMSE dan sMAPE
- 4. Melakukan peramalan dengan menggunakan metode Support Vector Regression dengan fungsi Gaussian (RBF) sebagai fungsi kernelnya dan lag-lag yang signifikan pada model ARIMA yang telah memenuhi asumsi.
- 5. Mendapatkan nilai dari parameter model SVR (C , γ dan ε) yang kemudian akan dioptimasi dengan menggunakan GA dan PSO.
- 6. Melakukan optimasi dengan menggunakan metode Algoritma Genetika dan *Particle Swarm Optimization*.
 - A. Optimasi menggunakan Genetika Algoritma
 - a. Menentukan parameter (C , γ dan ε) sebagai vektor solusi yang disebut dengan kromosom.
 - b. Menggunakan nilai parameter yang didapatkan dari tahap 5 sebagai *good initial value*.
 - c. Menentukan fitness function yang digunakan untuk menghitung nilai fitness dimana individu dengan nilai fitness terendah merupakan individu yang mampu bertahan hidup. *Fitness function* yang digunakan merupakan nilai RMSE.
 - d. Melakukan pemilihan pada individu dan digunakan sebagai orang tua menggunakan seleksi *roulette wheel*.
 - e. Melakukan pindah silang pada individu yang terpilih sebagai orang tua dan mendapatkan individu baru.
 - f. Melakukan mutasi pada individu dengan mengganti sebuah nilai dari minimal salah satu parameter dengan sebuah nilai baru.
 - g. Mempertahankan individu dengan nilai fitness terbaik sehingga tidak punah dan tetap bertahan hidup.

- h. Mendapatkan nilai optimal dari nilai parameter dari fungsi kernel.
- i. Mendapatkan peramalan untuk data out-sample dengan nilai parameter SVR yang telah optimal.
- B. Optimasi menggunakan *Particle Swarm Optimization*
 - a. Melakukan inisialisasi pada tiap parameter (C , γ dan ε) yang diperlukan (jumlah partikel, inertia weight, batas maksimum iterasi)
 - b. Menentukan *fitness function* yang digunakan untuk mengetahui tingkat kebaikan wilayah tersebut.
 - c. Melakukan pergeseran pada tiap partikel dengan jarak dan percepatan tertentu.
 - d. Menghitung nilai fitness dari partikel setelah dilakukan pergeseran
 - e. Melakukan pergeseran selama iterasi dengan batas tertentu
 - f. Mendapatkan nilai best solution dari tiap individu.
 - g. Mendapatkan Global Best Solution dari keseluruhan populasi.
 - h. Melakukan peramalan menggunakan peramalan dengan nilai parameter yang telah optimal.
- 7. Membandingkan nilai RMSE dan sMAPE dari empat metode dan mendapatkan metode terbaik.


3.4 Diagram Alir




Gambar 3.1 Diagram Alir Penelitian




Gambar 3.2 Diagram Alir Peramalan Menggunakan ARIMA



Gambar 3.3 Diagram Alir Peramalan Menggunakan SVR



Gambar 3.4 Diagram Alir Peramalan dengan Metode SVR-GA



Gambar 3.5 Diagram Alir Peramalan dengan Metode SVR-PSO

(Halaman sengaja dikosongkan)

BAB IV

ANALISIS DAN PEMBAHASAN

Pada bab ini akan dilakukan pembahasan mengenai langkah analisis, pembentukan dan optimasi parameter model beban listrik. Pemodelan beban listrik dilakukan di 14 wilayah dengan menggunakan ARIMA-SVR. Kemudian parameter dari model SVR dioptimasi dengan menggunakan GA dan PSO. Kebaikan model dari semua metode dibandingkan dengan metode yang lain melalui nilai SMAPE dan RMSE. Kemudian akan diketahui antara metode GA dan PSO, dengan nilai akurasi lebih baik.

4.1 Karakteristik Permintaan Beban Listrik di Setiap Kota di Jawa Timur

Pertama akan dilakukan deskripsi data untuk mengetahui karakteristik dari permintaan beban listrik pada 14 wilayah di Jawa Timur yang terdiri dari beberapa kota dan kabupaten yang berdekatan dan dikategorikan dalam 3 wilayah utama yaitu Barat, Timur dan Tengah. Data dicatat setiap hari pada siang (10.00 WIB) dan malam (19.00 WIB) mulai Januari hingga Desember 2016 sebagai in-sampel dan Januari 2017 hingga Februari 2017 sebagai Outsampel. Berikut merupakan deskriptif dari permintaan beban listrik dalam Mega Watt yang ditampilkan dalam Tabel 4.1

Tabel 4.1 Karakteristik Permintaan Beban Listrik untuk Setiap Kota di Jawa Timur


Wilayah	Kota	Mean	Minimum	Median	Maximum
Tengah	Surabaya	59796	27019	62399	71126
	Sidoarjo	22183	7460	22614	28666
	Gresik	13307	5715	13623	16345
	Pamekasan	8680	4834	8164	12166

Tabel 4.1 (Lanjutan)

Wilayah	Kota	Mean	Minimum	Median	Maximum
Timur	Pasuruan	23862	10045	24962	27837
	Malang	17961	9801	17549	21575
	Jember	10126	5688	9344	13237
	Banyuwangi	6453.8	4257	6680.5	8999
	Situbondo	3837.6	2550	3773	5373
Barat	Mojokerto	23958	10669	24625	27790
	Kediri	15127	9357	14683	18904
	Bojonegoro	13153	8025	12645	16597
	Madiun	8599.9	5497	8221	11259
	Ponorogo	5350.9	3271	5306.5	7269

Tiga wilayah yang dikelompokkan oleh PLN adalah bagian Tengah, Timur dan Barat. Bagian Tengah terdiri dari kota Surabaya (SBY), Sidoarjo (SDA), Gresik (GSK) dan Pamekasan (PKS). Bagian Timur terdiri dari kota Pasuruan (PSR), Malang (MLG), Jember (JBR), Banyuwangi (BWG) dan Situbondo (STB). Dan bagian Barat terdiri dari Mojokerto (MJK), Kediri (KDR), Bojonegoro (BJN), Madiun (MDN) dan Ponorogo (PNG). Permintaan beban listrik pada kota atau kabupaten yang tidak tertera dalam tabel diatas, sudah diakumulasikan kedalam kota yang tertera dalam tabel. Nilai rata-rata permintaan beban listrik dari tiap kota memiliki variasi yang berbeda-beda. Dari Tabel 4.1 dapat diketahui nilai rata-rata, median, nilai terendah dan tertinggi dari permintaan beban listrik di tiap kota. Pada bagian Tengah, SBY merupakan kota dengan permintaan beban listrik tertinggi di Jawa Timur. Rata-


rata permintaan bebannya dalam satu siang atau malam adalah sebesar 59796 MW, dengan permintaan beban terendah sebesar 27019 dimana memiliki nilai yang lebih besar dari nilai tertinggi milik 9 kota lainnya. Hal tersebut disebabkan karena SBY merupakan kota yang terbesar, setelah Jakarta, di Indonesia dan Ibukota dari Provinsi Jawa Timur. Sedangkan untuk bagian timur dan barat, kota dengan rata-rata permintaan beban tertinggi adalah Pasuruan dan Mojokerto. Situbondo merupakan kota dengan rata-rata permintaan beban listrik terendah di Jawa Timur. Rata-rata permintaan beban yang dimiliki hanya sebesar 3837.6 yang kurang dari 10% nilai rata-rata permintaan beban dari Surabaya. Dengan adanya variasi dari permintaan beban dari tiap kota, dapat muncul variasi lain dari permintaan beban listrik. Variasi tersebut dapat dilihat dari Gambar 4.1



Gambar 4.1 Karakteristik Beban Listrik Berdasarkan hari


Variasi yang diduga muncul dalam permintaan beban listrik adalah variasi permintaan secara mingguan, dimana

beban listrik memiliki nilai permintaan beban yang hampir sama pada hari tertentu. Gambar 4.1 merupakan grafik garis permintaan beban listrik dari setiap kota yang dilihat dari rata-rata permintaan beban listrik setiap harinya. Dari gambar tersebut diketahui bahwa terdapat beberapa kota seperti Surabaya, Mojokerto, Sidoarjo dan lainnya memiliki variasi permintaan beban secara mingguan. Hal tersebut dilihat dengan adanya pola menurun pada hari Sabtu dan Minggu. Hal tersebut bisa disebabkan karena tidak adanya kegiatan kantor dan beberapa pabrik pada hari tersebut. Di kota lainnya seperti Situbondo, Jember, Kediri dan lainnya, beban listrik cenderung untuk tidak dipengaruhi pola mingguan. Pola dari permintaan beban untuk kota tersebut hanya turun sedikit dan tidak terlihat pada hari Minggu. Selain pola mingguan, akan dilihat pola permintaan saat siang hari dan malam hari yang dapat dilihat pada Gambar 4.2



Gambar 4.2 Karakteristik Beban Listrik Tiap Kota Berdasarkan Siang dan Malam

Data yang digunakan merupakan data sampel yang diambil pada siang hari (10.00 WIB) dan malam hari (19.00 WIB) maka ingin diketahui apakah pola siang dan malam berbeda. Dari gambar 4.2 dapat diketahui bahwa untuk beberapa kota dengan permintaan beban listrik yang tinggi, seperti Surabaya, Mojokerto dan Pasuruan, perbedaan permintaan pada siang dan malam tidak terlihat berbeda. Hal tersebut diduga karena pada kota-kota tersebut banyak gedung yang digunakan sebagai kantor sehingga pemakaian listrik pada malam hari lebih kecil daripada siang hari. AC dan beberapa lampu di kantor akan dimatikan selama malam hari sehingga akan mengurangi permintaan beban pada malam hari. Dilain sisi, untuk kota dengan permintaan beban yang relatif lebih rendah, seperti, Pamekasan, Jember dan Madiun, permintaan pada siang dan malam terlihat terdapat perbedaan. Kemudian selain pola mingguan dan siang-malam, ingin diketahui pola permintaan perbulan dalam setahun yang dapat dilihat pada Gambar 4.3



Gambar 4.3 Karakteristik Rata-Rata Beban Listrik Setiap Bulan


Gambar 4.3 merupakan karakteristik permintaan dari bulan ke bulan untuk setiap kota dan kabupaten. Dari Gambar 4.3 dapat diketahui bahwa permintaan beban listrik untuk setiap kota cenderung naik, meskipun kenaikannya tidak terlihat dengan jelas. Beberapa kota mengalami penurunan yang cukup signifikan pada bulan Juni. Hal tersebut diduga karena adanya pengaruh dari hari Idul Fitri yang terdapat pada bulan Juni 2016. Dari informasi yang didapatkan terdapat variasi mingguan dan siang-malam. Variasi musiman yang akan digunakan pada pemodelan adalah musiman mingguan.

4.2 Pemodelan Permintaan Beban Listrik dengan Menggunakan ARIMA

Pada subbab ini akan dilakukan pemodelan ARIMA untuk meramalkan beban listrik pada 14 kota atau kabupaten di Jawa Timur. Berikut merupakan analisis dan pembahasan yang telah didapatkan untuk mendapatkan model terbaik.


4.2.1 Pemodelan Permintaan Beban Listrik di Kota Surabaya Menggunakan ARIMA

Hal pertama yang perlu dilakukan, sebelum melakukan peramalan dengan ARIMA, adalah melihat pola data melalui *time series plot* pada Gambar 4.4.



Gambar 4.4 *Time Series Plot* Beban Listrik Kota Surabaya (a) Reguler dan (b) Berdasarkan Hari


Dengan melihat pola dari *time series plot* dapat diketahui apakah data sudah stasioner dalam *mean* dan *varians*, kemudian melihat pola permintaan yang musiman. Dari Gambar 4.4 (a) dapat diketahui bahwa data belum stasioner dalam *mean* dan *varians* karena terdapat permintaan beban pada hari tertentu yang lebih rendah dibandingkan dengan hari yang lain karena pada awal bulan Ramadhan. Kemudian dari Gambar 4.4 (b) dapat diketahui bahwa permintaan beban listrik di Surabaya memiliki pola musiman. Pada gambar tersebut, permintaan beban pada hari Minggu memiliki permintaan beban yang lebih rendah jika dibandingkan dengan hari lain. Selain dengan menggunakan *time series plot*, stasioneritas dalam *varians* dapat diketahui dengan melakukan transformasi *box-cox*.



Gambar 4.5 Transformasi Box-Cox untuk Kota Surabaya


Transformasi yang dilakukan berdasarkan nilai *rounded lambda* yang dihasilkan. Jika nilai *rounded lambda* bernilai satu atau batas atas dan bawah melalui angka satu, maka tidak perlu dilakukan transformasi. Pada Gambar 4.5, diketahui bahwa nilai *rounded lambda* sama dengan 5, maka tidak perlu dilakukan transformasi karena secara teori jika nilai dipangkatkan dengan nilai lebih besar dari satu maka akan semakin besar variansi yang dimiliki.

Setelah diketahui data sudah stasioner dalam *varians*, langkah selanjutnya adalah melakukan pengecekan stasioneritas dalam *mean* dengan melihat pola dari plot ACF pada gambar 4.6. Berdasarkan Gambar 4.6 dapat diketahui bahwa pola ACF sudah membentuk gelombang sinus teredam sehingga dapat dikatakan data telah stasioner dalam *mean*. Kemudian berdasarkan hasil uji *dickey fuller*, *p-value* yang dihasilkan lebih kecil dari 0,01 sehingga dapat disimpulkan tolak H_0 , dimana H_1 data telah stasioner dalam *mean*. karena model diduga memiliki pola musiman mingguan akan dilakukan *differencing* pada lag musiman terlebih dahulu kemudian reguler.




Gambar 4.6 ACF Plot Beban Listrik Kota Surabaya

Tetapi berdasarkan Gambar 4.6, lag ACF pada kelipatan 14 memiliki nilai yang tinggi dan memiliki pola turun lambat sehingga akan dilakukan *differencing* pada lag 14. Berikut merupakan plot ACF yang dihasilkan setelah dilakukan *differencing* pada lag 14.



Gambar 4.7 ACF Plot Beban Listrik Kota Surabaya Setelah *Differencing* pada Lag ke 14

Dari Gambar 4.7 dapat diketahui bahwa pola ACF membentuk pola yang turun lambat sehingga dapat dikatakan data masih belum stasioner dalam *mean*. Karena data belum stasioner dalam *mean* maka akan dilakukan *differencing* reguler, yaitu pada lag 1. Berikut merupakan hasil ACF dan PACF plot setelah dilakukan *differencing* pada lag 14 dan 1.



Gambar 4.8 (a) Plot ACF dan (b) Plot PACF Beban Listrik Kota Surabaya Setelah *Differencing* lag 14 dan 1

Setelah dilakukan *differencing* pada lag 14 dan 1, data telah stasioner dalam *mean* karena lag telah *cut-off* pada lag 1 dan 14. Kemudian dilakukan identifikasi model ARIMA yang mungkin terbentuk dengan melihat lag yang signifikan pada plot ACF dan PACF. Lag yang signifikan pada Gambar

4.8 (a) adalah lag 1,3,8,9,14 dan pada Gambar 4.8 (b) adalah lag 1,3,9,14. Berikut merupakan model-model yang mungkin terbentuk dan pengujian signifikansi pada parameternya.

Setelah mendapatkan model yang mungkin terbentuk, langkah selanjutnya adalah melakukan pengujian signifikansi parameter dan mendapatkan model yang semua parameternya signifikan. Dari Tabel 4.2 dapat diketahui beberapa model yang dapat terbentuk dari identifikasi model. Model dikatakan memiliki parameter yang signifikan, jika nilai p-value yang dihasilkan bernilai kurang dari alfa ($\alpha = 0,05$). Dari 7 model diatas, terdapat 3 model yang memenuhi asumsi parameter signifikan adalah sebagai berikut, $ARIMA([1,3,9],1,0)(0,1,1)^{14}$, $ARIMA(1,1,0)(2,1,1)^{14}$ dan $ARIMA([3,9],1,1)(1,0,1)^{14}$.

Tabel 4.2 Hasil Uji Signifikansi Parameter untuk Model ARIMA Kota Surabaya

ARIMA([1,3,9],1,1)(1,1,1) ¹⁴	θ_1	-0,06251	0,6228
	Θ_{14}	0,82743	< 0,0001
	ϕ_1	-0,33873	0,0045
	ϕ_3	-0,10500	0,0086
	ϕ_9	-0,07825	0,0272
	Φ_{14}	0,03491	0,4522
ARIMA([1,3,9],1,0)(0,1,1) ¹⁴	Θ_{14}	0,81126	< 0,0001
	ϕ_1	-0,28479	< 0,0001
	ϕ_3	-0,11389	0,0015
	ϕ_9	-0,08012	0,0249

Tabel 4.2 (Lanjutan)

ARIMA(1,1,0)(1,1,1) ¹⁴	Θ_{14}	0,83456	< 0,0001
	ϕ_1	-0,30649	< 0,0001
	Φ_{14}	0,05152	0,2643
ARIMA(1,1,0)(2,1,1) ¹⁴	Θ_{14}	-0,99630	< 0,0001
	ϕ_1	-0,32752	< 0,0001
	Φ_{14}	-1,48177	< 0,0001
	Φ_{28}	-0,49920	< 0,0001
ARIMA([3,9],1,1)(1,0,1) ¹⁴	θ_1	0,31794	< 0,0001
	Θ_{14}	0,78469	< 0,0001
	ϕ_3	-0,14405	0,0001
	ϕ_9	-0,10202	0,0055
	Φ_{14}	0,99922	< 0,0001
ARIMA([1,3,9],1,[1,3,9])(1,1,1) ¹⁴	θ_1	0,01304	0,9205
	θ_3	-0,11015	0,3677
	θ_9	-0,07081	0,5422
	Θ_{14}	0,83031	< 0,0001
	ϕ_1	-0,26426	0,0349
	ϕ_3	-0,21092	0,0764
	ϕ_9	-0,13848	0,2076
	Φ_{14}	0,03428	0,4614

Setelah mendapatkan model yang mungkin terbentuk, langkah selanjutnya adalah melakukan pengujian signifikansi parameter dan mendapatkan model yang semua parameternya signifikan. Dari Tabel 4.2 dapat diketahui beberapa model yang dapat terbentuk dari identifikasi model. Model dikatakan memiliki parameter yang signifikan, jika nilai p-value yang

dihasilkan bernilai kurang dari alfa ($\alpha = 0,05$). Dari 7 model diatas, terdapat 3 model yang memenuhi asumsi parameter signifikan adalah sebagai berikut, $ARIMA([1,3,9],1,0)(0,1,1)^{14}$, $ARIMA(1,1,0)(2,1,1)^{14}$ dan $ARIMA([3,9],1,1)(1,0,1)^{14}$.

Tabel 4.3 Pengujian Asumsi *White Noise* dan Distribusi Normal

Model	White Noise		Uji Normalitas
	lag	p-value	p-value
ARIMA (1,1,0)(2,1,1) ¹⁴	6	0,0014	<0,01
	12	0,0025	
	18	0,0009	
	24	0,0038	
	30	<,0001	
	36	<,0001	
ARIMA ([3,9],1,1)(1,0,1) ¹⁴	6	0,1998	<0,01
	12	0,4080	
	18	0,6351	
	24	0,6508	
	30	0,8672	
	36	0,9563	
ARIMA([1,3,9],1,0)(0,1,1) ¹⁴	6	0,7896	<0,01
	12	0,3489	
	18	0,2637	
	24	0,4198	
	30	0,4135	
	36	0,3085	

Langkah selanjutnya adalah melakukan pengecekan residual untuk asumsi yang kedua. Asumsi kedua yaitu residual yang berdistribusi normal dan merupakan proses yang *white noise*.

Residual dikatakan merupakan proses yang *white noise* jika nilai p-value dari tiap lag untuk kolom *white noise* pada tabel 4.3, memiliki nilai lebih besar dari alfa ($\alpha = 0,05$). Dari ketiga model yang telah memenuhi asumsi signifikan parameter diatas, diketahui hanya dua model saja yang memenuhi asumsi *white noise* adalah dua model berikut, $ARIMA([1,3,9],1,0)(0,1,1)^{14}$ dan $ARIMA([3,9],1,1)(1,0,1)^{14}$. Tetapi kedua model tersebut tidak memenuhi asumsi distribusi normal karena nilai p-value dari uji normalitas bernilai lebih kecil dari alfa ($\alpha = 0,05$). Untuk mengatasi model yang residualnya tidak berdistribusi normal dapat dilakukan dengan pemodelan *ARIMA outlier*.

Dari kedua model yang telah memenuhi asumsi *white noise*, hanya satu model yang dimodelkan menggunakan *ARIMA outlier*. Model dipilih berdasarkan nilai kebaikan model sMAPE yang lebih kecil. Nilai sMAPE yang dihasilkan untuk model $ARIMA([1,3,9],1,0)(0,1,1)^{14}$ adalah 34,78% dan sMAPE untuk model $ARIMA([3,9],1,1)(1,0,1)^{14}$ adalah 34,81% maka model yang akan dimodelkan dengan *ARIMA outlier* adalah $ARIMA([1,3,9],1,0)(0,1,1)^{14}$.


Berdasarkan $ARIMA([1,3,9],1,0)(0,1,1)^{14}$ pengamatan yang merupakan *Additive Outlier* adalah pengamatan ke 511,459,137,693 dan 77. Berikut merupakan hasil dari *ARIMA outlier*,

Tabel 4.4 Hasil Pengujian Asumsi untuk Model ARIMA *Outlier* kota Surabaya

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	lag	p-value	p-value
ARIMA ([1,3,9],1,0)(0,1,1) ¹⁴	Θ_{14}	0,74932	<0,0001	12	0,0129	< 0,01
	ϕ_1	-0,35473	<0,0001	18	0,1073	
	ϕ_3	-0,09487	0,0093	24	0,1429	
	ϕ_9	-0,08182	<0,0001	30	0,2826	
	AO ₁	-21,25411	<0,0001	36	0,4938	
	AO ₂	-17,95854	<0,0001			
	AO ₃	-16,8913	<0,0001			
	AO ₄	-16,43857	<0,0001			
	AO ₅	0	<0,0001			

Tabel 4.4 merupakan pengujian asumsi untuk model dari ARIMA *outlier* dari model yang terpilih. Dari tabel 4.4 dapat diketahui setelah dimodelkan dengan ARIMA *outlier*, *residual* tetap tidak berdistribusi normal dan menyebabkan *residual* tidak *white noise*. Karena setelah dilakukan pemodelan dengan menggunakan ARIMA *outlier*, asumsi normal tidak dapat dipenuhi maka asumsi yang akan digunakan pada ARIMA hanya sampai pada asumsi *white noise*. Hal tersebut mengacu pada tujuan utama pada penelitian ini, yaitu mengetahui keunggulan antara ARIMA dan SVR dimana SVR tidak memiliki asumsi yang harus dipenuhi. Kemudian akan dibandingkan SVR dengan input model ARIMA yang memenuhi asumsi signifikan + *white noise* dan ARIMA yang memenuhi asumsi signifikan saja.

Nilai kebaikan model yang dihasilkan dari hasil ramalan out-sampel ARIMA([1,3,9],1,0)(0,1,1)¹⁴ adalah sebesar 34,78% untuk sMAPE dan 17945,12 untuk RMSE. Dari nilai sMAPE dapat diketahui bahwa hasil ramalan kurang baik, karena tingkat kesalahan yang dibentuk sebesar 34%. Apabila diplotkan maka akan membentuk grafik sebagai berikut.




Gambar 4.9 Plot Hasil Ramalan *Out-sample* Kota Surabaya

Model ramalan yang baik merupakan model yang memiliki hasil ramalan dengan nilai ramalan yang mendekati data asli. Dari Gambar 4.9 dapat diketahui bahwa ramalan dari model ARIMA kurang baik, karena ramalan bergerak turun dan menjauhi data asli, meskipun pola ramalan sudah menyerupai data asli.

4.2.2 Pemodelan Permintaan Beban Listrik di Kota Sidoarjo Menggunakan ARIMA

Kemudian peramalan dengan menggunakan ARIMA akan dilanjutkan ke kota kedua, yaitu Sidoarjo. Sebelum


dilakukan pemodelan, akan dilihat pola yang dibentuk dari *time series plot* kota Sidoarjo.



Gambar 4.10 *Time Series Plot* Beban Listrik Kota Sidoarjo (a) Reguler dan (b) Berdasarkan Hari


Dari Gambar 4.10 (a) dapat diketahui bahwa pola permintaan dari beban listrik di Sidoarjo menyerupai pola permintaan beban listrik di kota Sidoarjo. Dan terdapat beberapa pengamatan yang turun selama seminggu. Bentuk pola pada gambar tersebut dikatakan tidak stasioner dalam *mean* dan *varians* karena terdapat pengamatan yang terletak cukup jauh dibawah pengamatan lain. Dan dari Gambar 4.10 (b) dapat diketahui bahwa permintaan beban di Sidoarjo juga dipengaruhi pola musiman mingguan. Hal tersebut diketahui karena permintaan pada hari Minggu, memiliki permintaan beban yang lebih rendah dibandingkan dengan hari lain.

Kemudian akan dilakukan pengecekan stasioneritas dalam *varians* dengan melakukan transformasi *box-cox*. Pada gambar 4.11 (a) diketahui bahwa nilai *rounded lambda* adalah sebesar 0,5 sehingga dapat dikatakan data belum stasioner dalam *varians*. Karena data belum stasioner dalam *varians* maka akan dilakukan transformasi pada data berdasarkan nilai *rounded lambda*.



Gambar 4.11 Transformasi *Box-cox* untuk Kota Sidoarjo (a) Sebelum Transformasi dan (b) Setelah Transformasi


Transformasi yang dilakukan adalah $Y_t = Z_t^{0.5}$ dan kemudian dilakukan transformasi *box-cox* lagi. Hasil *rounded lambda* setelah transformasi adalah sebesar 1 maka dapat dikatakan data telah stasioner dalam *varians*. dan kemudian pengecekan stasioneritas dalam *mean* dapat dilakukan dengan melihat pola ACF berikut.



Gambar 4.12 Plot ACF Kota Sidoarjo (a) Tanpa *Differencing* dan (b) Setelah *Differencing* 14

Berdasarkan plot ACF pada Gambar 4.12 (a) dapat diketahui bahwa data sudah stasioner dalam *mean* karena pola ACF membentuk gelombang sinus teredam. Tetapi jika dilihat pada lag kelipatan 14, ACF memiliki nilai yang tinggi dan membentuk pola turun lambat sehingga akan dilakukan *differencing* pada lag 14. Setelah dilakukan *differencing* pada

lag 14, plot ACF membentuk pola turun lambat yang dapat dilihat pada Gambar 4.12 (b) sehingga dapat dikatakan data belum stasioner dalam *mean*. Karena data belum stasioner dalam *mean* maka akan dilakukan *differencing* lagi pada lag 1. Dan berikut merupakan hasil plot ACF dan PACF yang terbentuk.



Gambar 4.13 (a) Plot ACF dan (b) Plot PACF Kota Sidoarjo
Setelah *Differencing* 14 dan 1

Dari Gambar 4.13 (a), dapat diketahui bahwa pola ACF sudah *cut-off* pada lag 14 dan 1, sehingga dapat dikatakan bahwa data telah stasioner dalam *mean*. Setelah diketahui bahwa data telah stasioner dalam *mean* dan *varians* maka langkah selanjutnya adalah melakukan identifikasi model ARIMA dengan melihat plot ACF dan PACF. Berdasarkan Gambar 4.13 (a) lag yang signifikan adalah lag 1,2,3,14 dan pada Gambar 4.13(b) lag yang signifikan adalah lag 1,3,14,28.

Berdasarkan Tabel 4.5 dapat diketahui beberapa model yang dapat dibentuk dari langkah identifikasi model. Dari kelima model diatas terdapat tiga model yang memenuhi asumsi signifikan parameter.

Tabel 4.5 Uji Signifikansi Model ARIMA untuk Kota Sidoarjo

Model	Paramter	p-value
ARIMA(3,0,1)(1,1,0) ¹⁴	θ_1	-0,74155
	ϕ_1	-0,28885
	ϕ_2	0,72912
	ϕ_3	0,19446
	Φ_{14}	-0,4584
ARIMA([1,3],1,3)(2,1,1) ¹⁴	θ_1	-0,91839
	θ_2	0,5143
	θ_3	0,43269
	Θ_{14}	0,80666
	ϕ_1	-1,38614
	ϕ_3	0,38784
	Φ_{14}	0,06352
	Φ_{28}	0,03615
ARIMA([1,3],1,3)(0,1,1) ¹⁴	θ_1	-0,50311
	θ_2	0,29262
	θ_3	0,08809
	Θ_{14}	0,7809
	ϕ_1	-0,97639
	ϕ_3	0,07206
ARIMA([1,3],1,0)(0,1,1) ¹⁴	Θ_{14}	0,79684
	ϕ_1	-0,45392
	ϕ_3	-0,135
ARIMA(4,0,0)(0,1,1) ¹⁴	Θ_{14}	0,6745
	ϕ_1	0,44765
	ϕ_2	0,37346
	ϕ_3	0,14508
	ϕ_4	0,14468

Hal tersebut dapat dilihat pada kolom p-value dari semua parameter di cetak tebal. Model ARIMA yang memenuhi asumsi signifikan parameter dan kemudian akan lakukan pengujian asumsi ke 2 adalah $ARIMA(4,0,0)(0,1,1)^{14}$, $ARIMA([1,3],1,0)(0,1,1)^{14}$ dan $ARIMA(3,0,1)(1,1,0)^{14}$. Berikut merupakan hasil pengujian untuk asumsi yang kedua, yaitu residual yang *white noise* dan berdistribusi normal.

Tabel 4.6 Uji pada Asumsi *White Noise* dan Distribusi Normal

Model	<i>White Noise</i>		Uji Normalitas
	lag	p-value	p-value
$ARIMA(4,0,0)(0,1,1)^{14}$	6	0,0149	<0,01
	12	0,1166	
	18	0,0612	
	24	0,0757	
	30	<,0001	
	36	<,0001	
$ARIMA([1,3],1,0)(0,1,1)^{14}$	6	0,4415	<0,01
	12	0,8154	
	18	0,9129	
	24	0,9197	
	30	0,7295	
	36	0,6808	
$ARIMA(3,0,1)(1,1,0)^{14}$	6	0,5073	<0,01
	12	0,5101	
	18	0,8173	
	24	0,7883	
	30	0,9323	
	36	0,7511	

Model yang memenuhi asumsi *white noise* adalah model $ARIMA(3,0,1)(1,1,0)^{14}$ dan $ARIMA([1,3],1,0)(0,1,1)^{14}$ karena nilai p-value untuk pengujian asumsi *white noise* memiliki nilai lebih besar dari alfa (0,05) untuk setiap lagnya pada Tabel 4.6. Dan dari kedua model tersebut tidak ada model yang memenuhi asumsi distribusi normal karena hasil dari uji KS menghasilkan p-value yang bernilai lebih kecil dari alfa ($\alpha=0,05$). Kemudian akan dilakukan pemodelan dengan menggunakan *ARIMA outlier* untuk model $ARIMA([1,3],1,0)(0,1,1)^{14}$ dengan pengamatan 511,459,77,693 sebagai *additive outlier* dan 371 sebagai *shift outlier*.


Tabel 4.7 Pengujian Asumsi *ARIMA Outlier* Kota Sidoarjo

Model	Signifikansi Parameter			<i>White Noise</i>		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,3],1,0)(0,1,1) ¹⁴	Θ_{14}	0,74099	<0,0001	6	0,0334	< 0,01
	ϕ_1	-0,54416	<0,0001	12	0,009	
	ϕ_3	-0,09271	0,0093	18	0,0029	
	AO ₁	-1,55607	<0,0001	24	0,0143	
	AO ₂	-1,18414	<0,0001	30	0,0176	
	AO ₃	-0,82809	<0,0001	36	0,023	
	AO ₄	-0,80786	<0,0001			
	AO ₅	-0,96987	<0,0001			

Dari Tabel 4.7 dapat diketahui bahwa pemodelan dengan menggunakan *ARIMA outlier* tidak menghasilkan yang lebih baik. Karena residual yang dihasilkan belum berdistribusi normal dan residual menjadi tidak *white noise*. Seperti peramalan pada kota Surabaya, maka asumsi normal akan diabaikan dan

dilanjutkan pada perhitungan nilai kebaikan model dari Model ARIMA([1,3],1,0)(0,1,1)¹⁴.

Nilai kebaikan model yang dihasilkan dari Model ARIMA([1,3],1,0)(0,1,1)¹⁴ adalah 51.09% untuk sMAPE dan 9536, 03 untuk RMSE. Berdsarkan nilai sMAPE, hasil ramalan untuk model ARIMA tersebut kurang baik, karena tingkat kesalahan yang dibentuk lebih dari 51%. Dan jika hasil ramalan tersebut di tampilkan dalam bentuk plot, dapat dilihat pada gambar 4.14 berikut.




Gambar 4.14 Plot Hasil Ramalan *Out-sample* untuk Kota Sidoarjo

Dapat dilihat dari plot antara data *out-sample* dan hasil ramalan pada Gambar 4.14, pola data ramalan bergerak turun, meskipun pola dari data ramalan menyerupai data asli. Karena pola yang tidak sesuai tersebut maka dapat dikatakan bahwa ramalan dengan menggunakan ARIMA tidak menghasilkan permalan yang cukup baik. Maka pada subbab 4.3 akan dilakukan pemodelan dengan menggunakan SVR dari input ARIMA

4.2.3 Pemodelan Permintaan Beban Listrik di Kota Gresik Menggunakan ARIMA


Langkah yang sama pada kota sebelumnya, pola data akan dilihat berdasarkan *time series plot* untuk menentukan stasioneritas dalam *mean* dan *varians*. Kemudian melihat

pengaruh musiman pada kota Gresik. Hal tersebut dapat dilihat pada Gambar 4.15 berikut.




Gambar 4.15 *Time Series Plot* Beban Listrik Kota Gresik (a) Reguler dan (b) Berdasarkan Hari

Dari Gambar 4.15 (a) dapat diketahui bahwa pola permintaan beban listrik di kota Gresik mirip dengan pola data dari kota Gresik. Pola musiman yang diperlihatkan dari Gambar 4.15(b) juga memberikan pola musiman yang sama dari kota Surabaya, yaitu musiman mingguan. Hal itu ditandai dengan permintaan pada hari Minggu yang selalu lebih rendah dibandingkan dengan hari-hari lainnya. Dari pola yang dibentuk dari *time series plot* tersebut, dapat dikatakan bahwa data tidak stasioner dalam *mean* dan *varians*. Untuk pengecekan stasioneritas dalam *varians* dapat dilakukan dengan melihat hasil dari transformasi *box-cox* berikut.



Gambar 4.16 Transformasi *Box-cox* pada Kota Gresik

Berdasarkan hasil transformasi *box-cox* pada Gambar 4.16 dapat diketahui bahwa data telah stasioner dalam *varians* karena nilai *rounded lambda* sama dengan satu. Kemudian akan dilakukan pengecekan stasioneritas dalam *mean* dengan melihat pola dari ACF plot berikut.




Gambar 4.17 Plot ACF Kota Gresik (a) Tanpa *Differencing* dan (b) Setelah *Differencing* 14

Data dikatakan stasioner dalam *mean* jika pola dari plot ACF membentuk pola sinus terendam atau *cut-off* setelah lag tertentu. Dari Gambar 4.17(a) diatas, dapat diketahui kota Gresik sudah stasioner dalam *mean* karena ACF nya membentuk pola sinus terendam. Tetapi dapat dilihat dari lag musmian 14, pola ACF tinggi dan menurun lambat sehingga dilakukan *differencing* pada lag 14. Dan berdasarkan gambar 14(b), *differencing* 14 belum menghasilkan data yang stasioner dalam *mean* karena ACF plot membentuk pola turun lambat. Kemudian dilakukan *differencing* pada lag 1 dan menghasilkan ACF dan PACF pada gambar 4.18.

ACF plot yang terbentuk setelah *differencing* 1 dan 14 yang dapat dilihat pada Gambar 4.18(a), menandakan bahwa data telah stasioner dalam *mean* karena ACF telah *cut-off* pada

lag 2. Setelah diketahui data telah stasioner dalam *mean* dan *varians* maka dilakukan identifikasi model ARIMA berdasarkan plot ACF dan PACF dari Gambar 4.18



Gambar 4.18 (a) Plot ACF dan (b) Plot PACF Kota Gresik Setelah Differencing 1 dan 14

Dari Gambar 4.18 dapat dibentuk beberapa model ARIMA berdasarkan ACF dan PACF plot. Pada ACF plot, lag yang signifikan adalah 1,2,14 dan PACF plot signifikan pada lag 1,3,14. Berikut merupakan beberapa model ARIMA yang dapat terbentuk.

Tabel 4.8 Pengujian Signifikansi Parameter untuk Kota Gresik

Model	Parameter	p-value
ARIMA([1,3],1,2)(1,1,1) ¹⁴	θ_1	0,11047
	θ_2	0,03584
	Θ_{14}	0,85558
	ϕ_1	0,2485
	ϕ_3	0,0629
	Φ_{14}	0,0902
ARIMA([1,2,24],0,0)(0,1,1) ¹⁴	Θ_{14}	<,0001
	ϕ_1	<,0001
	ϕ_2	<,0001
	ϕ_{24}	0,0477

Tabel 4.8 (lanjutan)

Model	Parameter		p-value
ARIMA([1,3],1,0)(0,1,1) ¹⁴	Θ_{14}	0,84132	0,0001
	ϕ_1	-0,42306	0,0001
	ϕ_3	-0,10393	0,0023
ARIMA(3,1,0)(1,0,1) ¹⁴	Θ_{14}	0,85661	<,0001
	ϕ_1	-0,45966	<,0001
	ϕ_2	-0,10446	0,0099
	ϕ_3	-0,16902	<,0001
	Φ_{14}	1	<,0001

Berdasarkan Tabel 4.8 dapat diketahui beberapa model ARIMA yang dapat terbentuk. ARIMA([1,2,24],0,0)(0,1,1)¹⁴, ARIMA(3,1,0)(1,0,1)¹⁴ dan ARIMA([1,3],1,0)(0,1,1)¹⁴ adalah model ARIMA yang memenuhi asumsi signifikan parameter karena semua parameternya bernilai lebih kecil dari alfa ($\alpha=0,05$). Kemudian dilakukan pengecekan asumsi *white noise* dan distribusi normal pada model tersebut.

Tabel 4.9 Pengujian Asumsi *White Noise* dan distribusi Normal pada Kota Gresik

Model	<i>White Noise</i>		Uji Normalitas
	lag	p-value	p-value
ARIMA(3,1,0)(1,0,1) ¹⁴	6	0,1921	<0,01
	12	0,2211	
	18	0,4599	
	24	0,0822	
	30	0,0906	
	36	0,2255	

Tabel 4.9 (Lanjutan)

Model	White Noise		Uji Normalitas
	lag	p-value	p-value
ARIMA([1,2,24],0,0)(0,1,1) ¹⁴	6	0,0074	<0,01
	12	0,2161	
	18	0,3703	
	24	0,2558	
	30	0,1284	
	36	0,3131	
ARIMA([1,3],1,0)(0,1,1) ¹⁴	6	0,1592	<0,01
	12	0,0876	
	18	0,1149	
	24	0,3389	
	30	0,4162	
	36	0,3386	


Berdasarkan Tabel 4.9 dapat diketahui model yang memenuhi asumsi *white noise* adalah kedua model berikut, yaitu ARIMA(3,1,0)(1,0,1)¹⁴ dan ARIMA([1,3],1,0)(0,1,1)¹⁴. Dari kedua model tersebut tidak ada model yang memenuhi asumsi distribusi normal. Dan dipilih model ARIMA([1,3],1,0)(0,1,1)¹⁴ yang akan dimodelkan dengan menggunakan ARIMA *outlier*. Pada model tersebut diidentifikasi terdapat *Adaptive Outlier* pada pengamatan ke 511,459,77,693 dan *Shift Outlier* pada pengamatan ke 371. Hasil pengujian asumsi pada model ARIMA *outlier* kota Gresik dapat dilihat pada Tabel 4.10. Pemodelan dengan *outlier* tidak menghasilkan hasil lebih baik

karena tidak membuat residual menjadi berdistribusi normal dan residual tidak *white noise*.

Tabel 4.10 Pengujian Asumsi ARIMA *Outlier* untuk Kota Gresik

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,3],1,0)(0,1,1) ¹⁴	Θ_{14}	0,82461	<,0001	6	0,0575	< 0,01
	ϕ_1	-0,45823	<,0001	12	0,3572	
	ϕ_3	-0,09968	0,0032	18	0,0519	
	AO ₁	-4,54123	<,0001	24	0,0786	
	AO ₂	-4,15567	<,0001	30	0,0374	
	AO ₃	-3,13587	<,0001	36	0,0685	
	AO ₄	-3,22975	<,0001			
	AO ₅	-3,44976	<,0001			

Setelah dilakukan pemodelan dengan *outlier* tetapi hasil tidak menjadi lebih baik maka asumsi normalitas tetap diabaikan sama seperti kota sebelumnya. Kemudian berikut merupakan plot hasil ramalan *outsample* dari model ARIMA([1,3],1,0)(0,1,1)¹⁴.




Gambar 4.19 Plot Hasil Ramalan *Out-Sample* untuk Kota Gresik

Dari Gambar 4.19 dapat diketahui bahwa ramalan dari model ARIMA memiliki hasil kurang baik, karena pola ramalan yang tidak memiliki nilai mendekati *out-sample*, meskipun pola bentuk dari ramalan sudah menyerupai bentuk data *out-sample*. Hasil kebaikan model yang dihasilkan pun kurang baik, yaitu 23,91% untuk sMAPE dan 3148 untuk RMSE. Dari nilai sMAPE tersebut diketahui bahwa tingkat kesalahan yang dihasilkan ramalan ARIMA mencapai 23,91%.

4.2.4 Pemodelan Permintaan Beban Listrik di Kota Pamekasan Menggunakan ARIMA


Seperti pada subbab sebelumnya, langkah pertama yang akan dilakukan adalah melihat pola data dari *time series plot* Kota Pamekasan.



Gambar 4.20 *Time Series Plot* Beban Listrik Kota Sidoarjo


Time series plot dapat digunakan untuk mengetahui secara visual apakah data telah stasioner dalam mean atau varians. Secara visual, dari Gambar 4.20 dapat diketahui bahwa data telah stasioner dalam varians dan mean. Tetapi pengecekan stasioneritas dalam varians juga akan dilakukan dengan melihat hasil dari transformasi *box-cox*. Berdasarkan Gambar 4.21(a) dapat diketahui bahwa data belum stasioner dalam varians karena

nilai *rounded lambda* yang dihasilkan dari transformasi *box-cox* sama dengan 0. Karena nilai *rounded lambda* bernilai 0 maka transformasi yang akan dilakukan adalah transformasi $\ln(Z_t)$ dan menghasilkan hasil transformasi pada Gambar 4.21(b). Karena nilai interval *rounded lambda* sudah melalui angka 1 maka dapat dikatakan bahwa data telah stasioner dalam varians.



Gambar 4.21 Transformasi *Box-Cox* untuk Kota Pamekasan (a) Sebelum Transformasi dan (b) Setelah Transformasi


Setelah diketahui bahwa data telah stasioner dalam varians, langkah selanjutnya adalah melihat apakah data sudah stasioner dalam *mean* melalui plot ACF berikut.



Gambar 4.22 ACF Plot Kota Pamekasan (a) Tanpa *Differencing* dan (b) *Differencing* lag 1

Berdasarkan plot ACF pada Gambar 4.212(a), dapat dikatakan bahwa data belum stasioner dalam *mean* karena pola ACF yang turun lambat maka perlu dilakukan *differencing* pada

lag 1. Setelah dilakukan *differencing*, pola ACF yang dapat dilihat pada Gambar 4.22(b) masih memiliki pola turun lambat sehingga akan dilakukan *differencing* lagi pada lag 14. Dan berikut merupakan hasil ACF dan PACF plot setelah *differencing* pada lag 1 dan 14.



Gambar 4.23 (a) ACF Plot dan (b) PACF plot untuk Kota Pamekasan Setelah *Differencing* 14 dan 1

Setelah dilihat dari Gambar 4.23(a) bahwa data telah stasioner dalam mean karena sudah *cut-off* pada lag 1 dan 14. Kemudian akan dilakukan identifikasi model ARIMA berdasarkan ACF dan PACF. Lag yang signifikan pada plot ACF adalah 1,2,14 dan lag yang signifikan pada PACF adalah 1,2,3,14. Lag yang signifikan tersebut akan digunakan untuk membangun model ARIMA pada Tabel 4.11. Berikut merupakan hasil pengujian asumsi dan model yang mungkin terbentuk dari kombinasi lag yang signifikan.

Dari Tabel 4.11 dapat diketahui model ARIMA yang memenuhi asumsi yang diperlukan. Dari tabel diatas diketahui bahwa ketiga model yang ditampilkan merupakan model yang

memenuhi asumsi parameter yang signifikan karena semua parameter memiliki nilai p-value lebih kecil dari alfa ($\alpha=0,05$).

Tabel 4.11 Pengujian Asumsi pada Metode ARIMA kota Pamekasan


Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([2],1,1)(3,1,0) ¹⁴	θ_1	0,86456	0,0001	6	-	< 0,01
	ϕ_2	0,15939	0,0002	12	0,3359	
	Φ_{14}	-0,69326	0,0001	18	0,6275	
	Φ_{28}	-0,41416	0,0001	24	0,3449	
	Φ_{42}	-0,13627	0,0006	30	0,3952	
				36	0,5575	
ARIMA ([1,2,3,4,5,6,7,30], 1,0)(0,1,1) ¹⁴	Θ_{14}	0,81182	<,0001	6	,	<0,01
	ϕ_1	-0,80211	<,0001	12	0,0008	
	ϕ_2	-0,50128	<,0001	18	0,0141	
	ϕ_3	-0,37302	<,0001	24	0,0503	
	ϕ_4	-0,28889	<,0001	30	0,1365	
	ϕ_5	-0,21813	<,0001	36	0,2028	
	ϕ_6	-0,13667	0,0045			
	ϕ_7	-0,13033	0,0005			
	ϕ_{30}	0,06458	0,0321			
ARIMA (2,1,1)(3,1,0) ¹⁴	θ_1	-0,99317	<,0001	6	,	<0,01
	ϕ_1	-1,5572	<,0001	12	<,0001	
	ϕ_2	-0,56561	<,0001	18	<,0001	
	Φ_{14}	-0,68964	<,0001	24	<,0001	
	Φ_{28}	-0,42055	<,0001	30	<,0001	
	Φ_{42}	-0,1152	0,0042	36	<,0001	

Dan dari ketiga model tersebut hanya terdapat model yang memenuhi asumsi *white noise* yaitu ARIMA([2],1,1)(3,1,0)¹⁴. Hal tersebut diketahui dari Tabel 4.11 pada kolom pengujian *white noise* dimana nilai p-value yang harus lebih besar dari alfa ($\alpha=0,05$). Informasi lain yang didapatkan adalah ketiga model tersebut tidak memiliki residual yang tidak berdistribusi normal karena nilai p-value dari pengujian KS bernilai kurang dari alfa ($\alpha=0,05$). Untuk mengatasi model yang tidak normal dapat dilakukan pemodelan menggunakan ARIMA *outlier*. Berikut merupakan pemodelan ARIMA *outlier* pada model ARIMA([2],1,1)(3,1,0)¹⁴

Tabel 4.12 Pengujian Asumsi untuk Model ARIMA *Outlier* Kota Pamekasan

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([2],1,1)(3,1,0) ¹⁴	Θ_{14}	0,85318	<,0001	6	0,0889	< 0,01
	ϕ_2	0,18013	<,0001	12	0,2963	
	Φ_{14}	-0,68898	<,0001	18	0,5884	
	Φ_{28}	-0,38296	<,0001	24	0,7976	
	Φ_{42}	-0,10588	0,0083	30	0,608	
	AO ₁	-0,26009	<,0001	36	0,386	
	AO ₂	-0,26195	<,0001			
	AO ₃	0,21419	<,0001			
	AO ₄	-0,22006	<,0001			
	AO ₅	-0,18262	<,0001			

Dari Tabel 4.12 dapat diketahui bahwa pemodelan dengan menggunakan *outlier* tidak menghasilkan pemodelan dengan yang lebih baik karena uji normalitas tidak menghasilkan hasil yang berdistribusi normal. Peramalan akan dilanjutkan dengan mengabaikan asumsi distribusi normal. Dan berikut merupakan hasil plot antara hasil ramalan dan data *out-sample* pada Gambar 4.24.




Gambar 4.24 Plot Hasil Ramalan dan Data *Out-sample* Kota Pamekasan

Berdasarkan plot antara ramalan dan data *out-sample* pada Gambar 4.24, dapat diketahui bahwa pola ramalan bergerak naik dibandingkan dengan data *outsample*, meskipun pola ramalan sudah menyerupai data *outsample*. Hasil kebaikan model yang dihasilkan adalah sebesar 14,22% untuk sMAPE dan 1545,86 untuk RMSE. Dari nilai sMAPE, hasil peramalan kurang baik karena tingkat kesalahan yang dihasilkan sebesar 14,22% meskipun lebih kecil jika dibandingkan peramalan ARIMA dari kota-kota sebelumnya.


4.2.5 Pemodelan Permintaan Beban Listrik di Kota Pasuruan Menggunakan ARIMA

Langkah awal yang dilakukan adalah dengan melihat *time series plot* dari kota Pasuruan. Berdasarkan Gambar 4.25(a), *time series plot* dari kota Pasuruan menyerupai permintaan beban kota Surabaya. Sama halnya dengan kota Surabaya, secara visual, permintaan beban kota Pasuruan tidak stasioner dalam mean dan varians. Dan berdasarkan Gambar 4.25(b), pola musiman dari Pasuruan pun juga sama dengan kota Surabaya, yaitu memiliki musiman mingguan dimana permintaan pada hari Minggu lebih rendah jika dibandingkan dengan hari lain.




Gambar 4.25 *Time Series Plot* untuk Kota Pasuruan (a) Reguler dan (b) Berdasarkan Hari

Langkah selanjutnya adalah melakukan pengecekan stasioneritas dalam mean dan varians dengan melihat transformasi box-cox untuk varians dan plot ACF untuk mean. berikut merupakan hasil transformasi *box-cox*. Data dapat dikatakan stasioner dalam varians jika nilai *rounded lambda* yang dihasilkan bernilai sama dengan satu. Karena nilai *rounded lambda* pada Gambar 4.26 bernilai sama dengan 5, maka dapat dikatakan bahwa data telah stasioner dalam varians.



Gambar 4.26 Transformasi *Box-Cox* untuk Kota Pasuruan

Kemudian dilakukan pengecekan stasioneritas dalam *mean* dengan melihat pola ACF yang akan ditampilkan pada gambar berikut.




Gambar 4.27 Plot ACF untuk Kota Pasuruan (a) Tanpa *Differencing* dan (b) *Differencing* 14

Plot ACF yang terbentuk pada Gambar 4.27(a) membentuk pola gelombang sinus teredam sehingga dapat dikatakan bahwa data telah stasioner dalam *mean*. Tetapi jika dilihat dari lag musiman 14, pola ACF masih tinggi dan turun lambat sehingga akan dilakukan *differencing* pada lag 14. Plot ACF yang dihasilkan setelah *differencing* 14 dapat dilihat pada Gambar 4.27(b). Plot ACF membentuk pola turun lambat

sehingga dikatakan bahwa data belum stasioner dalam mean dan dilakukan *differencing* pada lag 1.

Berdasarkan Gambar 4.28 (a) dapat diketahui bahwa plot ACF setelah dilakukan *differencing* pada lag 14 dan 1, sudah menghasilkan pola yang *cut-down* sehingga dapat dikatakan bahwa data telah stasioner dalam mean. Langkah selanjutnya adalah melakukan identifikasi model.



Gambar 4.28 (a) Plot ACF dan (b) Plot PACF untuk Kota Pasuruan Setelah *Differencing* 14 dan 1

Dan setelah dilakukan pemodelan dengan mengkombinasikan dari lag-lag yang signifikan, menghasilkan beberapa model ARIMA sebagai berikut.

Berdasarkan Tabel 4.13, ketiga model yang ditampilkan merupakan model ARIMA yang memenuhi asumsi signifikansi parameter. Dan model yang memenuhi asumsi *white noise* adalah model $ARIMA([3,16],1,1)(1,1,1)^{14}$ karena nilai p-value pada pengujian untuk *white noise* menghasilkan nilai lebih besar dari α . Tetapi dari semua model tersebut tidak ada model yang memiliki residual yang berdistribusi normal. Sama dengan kota lainnya akan dilakukan pemodelan dengan menggunakan ARIMA *outlier*. Data yang diidentifikasi sebagai *Addaptive*

outlier adalah pengamatan ke 511,459,77,693 dan *Shift outlier* pada pengamatan ke 371.

Tabel 4.13 Pengujian Asumsi pada Model ARIMA Kota Pasuruan

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([3,16],1,1) (1,1,1) ¹⁴	θ_1	0,24662	0,0001	6	0,1417	< 0,01
	Θ_{14}	0,85657	0,0001	12	0,1019	
	ϕ_3	-0,07713	0,0403	18	0,291	
	ϕ_{16}	0,11101	0,0035	24	0,6563	
	Φ_{14}	0,14142	0,0026	30	0,3988	
				36	0,3194	
ARIMA ([1,16],1,0) (1,1,1) ¹⁴	Θ_{14}	0,86842	<,0001	6	0,0185	<0,01
	ϕ_1	-0,2315	<,0001	12	0,0167	
	ϕ_{16}	0,10211	0,0057	18	0,0621	
	Φ_{14}	0,14859	0,0013	24	0,2561	
				30	0,1769	
				36	0,1775	
ARIMA(0,1,0) (1,1,1) ¹⁴	Θ_{14}	0,87913	<,0001	6	<,0001	<0,01
	Φ_{14}	0,15034	0,0009	12	<,0001	
				18	<,0001	
				24	<,0001	
				30	<,0001	
				36	<,0001	

Berdasarkan Tabel 4.13, ketiga model yang ditampilkan merupakan model ARIMA yang memenuhi asumsi signifikansi parameter. Dan model yang memenuhi asumsi *white noise* adalah model ARIMA([3,16],1,1)(1,1,1)¹⁴ karena nilai p-value pada


pengujian untuk *white noise* menghasilkan nilai lebih besar dari α . Tetapi dari semua model tersebut tidak ada model yang memiliki residual yang berdistribusi normal. Sama dengan kota lainnya akan dilakukan pemodelan dengan menggunakan ARIMA *outlier*. Data yang diidentifikasi sebagai *Addaptive outlier* adalah pengamatan ke 511,459,77,693 dan *Shift outlier* pada pengamatan ke 371.

Berdasarkan Tabel 4.14 dapat diketahui bahwa model ARIMA *outlier* tidak memberikan hasil yang lebih baik karena residual tetap tidak berdistribusi normal. Selain itu residual juga menjadi tidak *white noise*. Sama halnya pada kota sebelumnya, model ARIMA akan mengabaikan asumsi *white noise* dan dilanjutkan dengan membandingkan hasil ramalan dengan data *outsample*

Tabel 4.14 Pemodelan ARIMA *Outlier* Kota Pasuruan

Model	Signifikansi Parameter			<i>White Noise</i>		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([3,16],1,1) (1,1,1) ¹⁴	Θ_{14}	0,31532	<,0001	6	0,0058	< 0,01
	ϕ_1	0,81855	<,0001	12	0,0006	
	ϕ_{16}	0,09821	0,0108	18	0,0017	
	Φ_{14}	0,16824	0,0009	24	0,0125	
	AO ₁	-9,68661	<,0001	30	0,0199	
	AO ₂	-7,27963	<,0001	36	0,0184	
	AO ₃	-6,46537	<,0001			
	AO ₄	-5,87115	<,0001			
	LS ₁	-7,92188	<,0001			

Selanjutnya akan dilakukan peramalan dengan menggunakan model $ARIMA([3,16],1,1)(1,1,1)^{14}$ pada data outsample dan menghasilkan plot sebagai berikut.




Gambar 4.29 Plot Antara Hasil Ramalan dan Data Outsample Kota Pasuruan

Berdasarkan Gambar 4.29 dapat diketahui bahwa pola hasil ramalan dari model ARIMA tidak menghasilkan ramalan yang baik karena pola dari hasil ramalan tidak memiliki nilai yang mendekati dari data outsample, meskipun pola dari data ramalan sudah menyerupai data asli. Nilai kebaikan model sMAPE dan RMSE yang dihasilkan adalah sebesar 48,95% dan 9556,03, yang artinya model peramalan ARIMA menghasilkan tingkat kesalahan sebesar 48,95%.


4.2.6 Pemodelan Permintaan Beban Listrik di Kota Malang Menggunakan ARIMA

Tahapan awal yang harus dilakukan adalah melihat pola data melalui TS plot dari Kota Malang untuk melihat stasioneritas dan pola musiman yang mungkin dapat terbentuk.



Gambar 4.30 Time Series Plot untuk Kota Malang (a) Reguler dan (b) Berdasarkan Hari


Berdasarkan TS plot pada Gambar 4.30 (a) dapat diketahui bahwa pola beban listrik kota Malang menyerupai beban listrik dari Kota Surabaya. Secara visual pola permintaan beban tidak membentuk pola yang stasioner dalam mean dan varians karena terdapat beberapa data yang lebih rendah dibandingkan dengan pengamatan lainnya. Begitu juga dengan pola musiman mingguannya, kota Malang memiliki permintaan beban yang lebih rendah pada hari Minggu. Tahapan selanjutnya adalah melihat stasioneritas data dalam varians melalui transformasi box-cox yang dapat dilihat pada gambar 4.31.




Gambar 4.31 Transformasi Box-Cox untuk Kota Malang

Berdasarkan hasil dari transformasi box-cox pada Gambar 4.31, dapat diketahui bahwa data sudah stasioner dalam

varians. Hal tersebut diketahui dengan melihat nilai *rounded lambda* yang dihasilkan sama dengan satu maka dikatakan bahwa data telah stasioner dalam varians. selanjutnya adalah pengecekan stasioneritas dalam mean dengan melihat plot ACF berikut.



Gambar 4.32 ACF Plot untuk Kota Malang (a) Sebelum Differencing dan (b) Setelah Differencing 1



Gambar 4.33 (a) ACF Plot dan (b) PACF plot untuk Kota Malang Setelah Differencing 14 dan 1

Berdasarkan plot ACF pada gambar 4.32 (a), dapat diketahui bahwa data belum stasioner dalam mean, karena plot ACF membentuk pola turun lambat. Karena data belum stasioner dalam mean maka akan dilakukan *differencing* pada lag 1. Pola ACF yang dihasilkan pada Gambar 4.32(b). Pola ACF tetap turun lambat sehingga akan dilakukan *differencing* lagi tetapi pada lag

musiman 14. Berikut merupakan hasil plot ACF dan PACF setelah *differencing* 14 dan 1

Berdasarkan gambar 4.33(a) dapat diketahui bahwa data telah stasioner dalam *mean* karena plot ACF sudah tidak membentuk pola yang turun lambat. Dan tahapan selanjutnya adalah melakukan identifikasi model ARIMA dengan melihat plot ACF dan PACF.

Tabel 4.15 Pengujian Asumsi pada Model ARIMA Kota Malang

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA([1,2,3,43,52],1,0)(0,1,1) ¹⁴	Θ_{14}	0,81288	0,0001	6	0,1235	< 0,01
	ϕ_1	-0,50375	0,0001	12	0,7283	
	ϕ_2	-0,19614	0,0001	18	0,4736	
	ϕ_3	-0,19181	0,0001	24	0,1868	
	ϕ_{43}	0,10325	0,0022	30	0,0658	
	ϕ_{52}	0,10166	0,0025	36	0,4147	
ARIMA([3,43,52],1,1)(2,1,1) ¹⁴	θ_1	0,54412	<,0001	6	,	<0,01
	Θ_{14}	-0,99578	<,0001	12	0,4546	
	ϕ_3	-0,12634	0,0009	18	0,0569	
	ϕ_{43}	0,13014	0,0007	24	0,2649	
	ϕ_{52}	0,10992	0,0044	30	<,0001	
	Φ_{14}	-1,4998	<,0001	36	<,0001	
	Φ_{28}	-0,52182	<,0001			
ARIMA([3],1,1)(2,1,1) ¹⁴	θ_1	0,55317	<,0001	6	<,0001	<0,01
	Θ_{14}	-1	<,0001	12	<,0001	
	ϕ_3	-0,12308	0,0015	18	<,0001	
	Φ_{14}	-1,51149	<,0001	24	<,0001	
	Φ_{28}	-0,52545	<,0001	30	<,0001	
				36	<,0001	

Berdasarkan Tabel 4.15 dapat diketahui bahwa ketiga model diatas merupakan model yang telah memenuhi asumsi signifikan parameter karena nilai p-value dari uji signifikansi parameter bernilai lebih kecil dari alfa ($\alpha=0,05$). Kemudian dari ketiga model tersebut, hanya terdapat satu model yang memenuhi asumsi *white noise*, yaitu ARIMA([3,16],1,1)(1,1,1)¹⁴. Sama seperti kota lainnya, tidak ada model yang memenuhi asumsi distribusi normal sehingga dari model diatas, yaitu ARIMA([3,16],1,1)(1,1,1)¹⁴, akan dilakukan pemodelan dengan menggunakan ARIMA *outlier* dengan pengamatan ke 138,332,511,459 dan 693 sebagai *Additive Outlier*. berikut merupakan hasil pemodelan ARIMA *outlier* kota Malang.


Tabel 4.16 Pengujian Asumsi pada Model ARIMA Kota Pasuruan

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA(3,1,0)(0,1,1) ¹⁴	Θ_{14}	-0,55021	<,0001	6	0,8177	< 0,01
	ϕ_1	-0,13628	0,0015	12	0,4434	
	ϕ_2	-0,12946	0,0006	18	0,1588	
	ϕ_3	-5,50557	<,0001	24	0,3182	
	AO ₁	-4,45444	<,0001	30	0,2113	
	AO ₂	-3,65167	<,0001	36	0,2043	
	AO ₃	-2,77446	<,0001			
	AO ₄	-2,79687	<,0001			
	AO ₅	0,76586	<,0001			

Berdasarkan Tabel 4.16 Model ARIMA dengan *outlier* tidak menghasilkan hasil yang lebih baik. Residual tidak berubah

menjadi berdistribusi normal dan menjadi tidak *white noise*. Oleh sebab itu, sama dengan model ARIMA dari kota lainnya, asumsi normal akan diabaikan dan dilanjutkan dengan peramalan pada data outsamplel.


Berdasarkan Gambar 4.34 dapat diketahui bahwa hasil ramalan dari outsamplel merupakan ramalan yang kurang baik karena nilai ramalan yang tidak mendekati data asli. Nilai sMAPE dan RMSE yang dihasilkan adalah sebesar 13,36% dan 2421,16.



Gambar 4.34 Plot Hasil Ramalan dengan Data Outsamplel Kota Malang

4.2.7 Pemodelan Permintaan Beban Listrik di Kota Jember Menggunakan ARIMA


Dengan tahapan yang sama dengan kota sebelumnya, untuk melakukan pemodelan perlu diketahui pola data dengan melihat pola pada *time series plot*. Berikut merupakan *time series plot* dari permintaan beban listrik kota Jember.



(a)


(b)

Gambar 4.35 Time Series Plot untuk Kota Jember (a) Reguler dan (b) Berdasarkan Hari



(a)

(b)




(c)

Gambar 4.36 Transformasi Box-Cox Kota Jember (a) Sebelum Transformasi (b) Setelah Transformasi Pangkat 0,5 dan (c) Setelah Transformasi Pangkat 0,25

Pola data yang dimiliki kota Jember memiliki pola yang hampir mirip dengan kota Pamekasan, yang terlihat terdapat perbedaan pada Siang dan Malam. Pada Gambar 4.35(b),


diketahui bahwa permintaan pada hari Minggu juga terlihat lebih rendah jika dibandingkan dengan hari yang lain karena pada plot, permintaan hari minggu terletak lebih rendah dari yang lain. Secara visual dari Gambar 4.35(a), permintaan beban listrik kota Jember sudah stasioner dalam *mean* dan *varians*. Tetapi agar jelas, stasioneritas dalam *varians* dilihat berdasarkan transformasi box-cox berikut.

Berdasarkan hasil transformasi box-cox pada Gambar 4.36(a), dapat diketahui bahwa permintaan dari kota Jember belum stasioner dalam *varians* karena nilai *rounded lambda* bernilai sama dengan 0,5. Karena data belum stasioner dalam *varians* maka dilakukan transformasi sesuai dengan nilai *rounded lambda* yang dihasilkan, yaitu $Z_t^{0.5}$. Setelah dilakukan transformasi, *rounded lambda* yang dihasilkan masih bernilai 0,5 maka akan dilakukan transformasi lagi dan menghasilkan *rounded lambda* sama dengan 1. Karena nilai *lambda* sama dengan 1 maka dapat dikatakan bahwa data telah stasioner dalam *varians*. Selanjutnya akan dilakukan pengecekan stasioneritas dalam *mean* dengan melihat pola ACF dari permintaan beban kota Jember.



Gambar 4.37 ACF Plot untuk Kota Jember (a) Sebelum Differencing dan (b) Setelah Differencing 1

Data akan dikatakan stasioner dalam mean jika pola dari ACF plot membentuk gelombang sinus teredam atau *cut-off* setelah lag tertentu. Pada Gambar 4.37(a) pola ACF membentuk pola turun lambat sehingga dapat dikatakan bahwa data belum stasioner dalam mean. Kemudian dilakukan *differencing* pada lag 1 dan menghasilkan ACF yang masih memiliki pola turun lambat pada Gambar 4.37(b). Karena masih membentuk pola yang turun lambat maka akan dilakukan *differencing* lagi pada lag 14



Gambar 4.38 (a) ACF Plot dan (b) PACF plot untuk Kota jember Setelah *Differencing* 1 dan 14

Berdasarkan Gambar 4.38(a) dapat diketahui bahwa data telah stasioner dalam mean karena ACF telah membentuk pola *cut-down* setelah lag ke 2. Dan lag yang signifikan pada ACF plot adalah 1,2,4,5,14 yang akan digunakan untuk membentuk model MA. Lag yang signifikan pada plot PACF berdasarkan Gambar 4.38(b) adalah lag 1,2,4,14. Dari lag-lag yang signifikan tersebut akan dilakukan identifikasi model untuk ARIMA. Berikut merupakan beberapa model yang terbentuk.

Tabel 4.17 Pengujian Asumsi pada Model ARIMA Kota Jember

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,2,3,4,5,16,36], 1,0)(0,1,1) ¹⁴	Θ_{14}	0,80154	0,0001	6	-	< 0,01
	ϕ_1	-0,70265	0,0001	12	0,0752	
	ϕ_2	-0,44427	0,0001	18	0,1096	
	ϕ_3	-0,40525	0,0001	24	0,0809	
	ϕ_4	-0,23755	0,0001	30	0,0843	
	ϕ_5	-0,15216	0,0001	36	0,1881	
	ϕ_{16}	0,06744	0,0243			
	ϕ_{36}	0,08485	0,0058			
ARIMA(3,1,0) (0,1,1) ¹⁴	Θ_{14}	0,81399	<,0001	6	<,0001	
	ϕ_1	-0,65521	<,0001	12	0,0003	
	ϕ_2	-0,34812	<,0001	18	0,0001	<0,01
	ϕ_3	-0,27075	<,0001	24	0,0004	
				30	0,0005	
				36	0,0001	


Berdasarkan Tabel 4.17 dapat diketahui model ARIMA diatas merupakan model ARIMA yang telah memenuhi asumsi signifikan parameter karena semua nilai p-value pada uji signifikansi parameter bernilai kurang dari α . Kemudian asumsi yang kedua adalah residual yang *white noise* dipenuhi hanya pada model ARIMA([1,2,3,4,5,16,36],1,0)(0,1,1). Hal tersebut dapat diketahui dengan melihat kolom *p-value* pada pengujian *white noise*. Tetapi model ARIMA tersebut tidak memenuhi asumsi normal sehingga perlu dimodelkan dengan

menggunakan ARIMA *outlier*. berikut merupakan pemodelan yang didapatkan.

Tabel 4.18 Pengujian Asumsi pada Model ARIMA Kota Jember

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([3,16],1,1)(1,1,1) ¹ ₄	Θ_{14}	0,74833	<,0001	6	,	< 0,01
	ϕ_1	-0,7253	<,0001	12	0,4369	
	ϕ_2	-0,43612	<,0001	18	0,5075	
	ϕ_3	-0,38021	<,0001	24	0,289	
	ϕ_4	-0,2246	<,0001	30	0,2596	
	ϕ_5	-0,15316	<,0001	36	0,2481	
	ϕ_{16}	0,05091	0,0893			
	ϕ_{36}	0,05338	0,0837			
	AO_1	-1,01735	<,0001			
	AO_2	-0,68456	<,0001			
	AO_3	-0,6908	<,0001			
	AO_4	-0,58738	<,0001			
	AO_5	-0,57077	<,0001			

Tabel 4.18 merupakan hasil pengujian asumsi model ARIMA dengan *outlier*. Pengamatan yang digunakan adalah pengamatan ke 332,296,62,560,511 sebagai *additive outlier*. Model ARIMA *outlier* diatas tidak menghasilkan hasil yang lebih baik karena residual masih belum berdistribubisi normal. hal tersebut dapat diketahui dari nilai p-value dari pengujian normalitas bernilai kurang dari α . Selanjutnya adalah peramalan pada data outsample dan akan dihitung nilai kebaikan modelnya.




Gambar 4.39 Plot Hasil Ramalan dengan Data Outsmample Model ARIMA Jember

Berdasarkan Gambar 4.39, hasil ramalan ARIMA pada kota Jember lebih baik daripada hasil ramalan dari kota-kota sebelumnya. Hasil ramalan sudah mendekati nilai dari data outsampel dan polanya pun sudah sesuai. Nilai kebaikan model yang dihasilkan pun lebih rendah dari kota sebelumnya, yaitu 4,63% untuk sMAPE dan 569,39 untuk RMSE.


4.2.8 Pemodelan Permintaan Beban Listrik di Kota Banyuwangi Menggunakan ARIMA

Tidak berbeda dengan pemodelan ARIMA pada kota sebelumnya, tahapan awal yang dilakukan adalah mengidentifikasi pola data melalui *time series plot*. Berikut merupakan *time series plot* dari kota Banyuwangi.



Gambar 4.40 *Time Series Plot* untuk Kota Banyuwangi


Dibandingkan dengan kota lain Banyuwangi terlihat memiliki pola time series plot yang berbeda. Pada Gambar 4.40 dapat diketahui bahwa Banyuwangi memiliki pola permintaan beban yang meningkat pada awal tahun dan akhir tahun 2016. Tetapi secara keseluruhan permintaan beban tersebut terlihat stasioner dalam mean dan varians. Selanjutnya adalah pengecekan stasioneritas dalam varians dengan melihat hasil dari transformasi box-cox berikut.



Gambar 4.41 Transformasi Box-Cox Kota Jember

Dari Gambar 4.41 dapat diketahui bahwa data telah stasioner dalam varians. hal tersebut dapat dikatakan dengan melihat nilai *rounded lambda* yang dihasilkan. Meskipun *rounded lambda* bernilai sama dengan 0, tetapi batas atas dan


batas bawahnya melalui angka 1 sehingga dapat dikatakan data tersebut telah stasioner dalam varians. Langkah selanjutnya adalah melihat stasioneritas dalam mean melalui ACF plot berikut.



Gambar 4.42 ACF Plot untuk Kota Banyuwangi (a) Sebelum *Differencing* dan (b) Setelah *Differencing* 1

Stasioneritas dalam mean dapat dilihat dari pola ACF yang dibentuk. Jika pola ACF membentuk pola turun lambat maka dapat dikatakan bahwa data tersebut belum stasioner dalam mean. Dari Gambar 4.42(a) dapat dikatakan bahwa data belum stasioner dalam mean karena pola ACF membentuk pola turun lambat, sehingga akan dilakukan *differencing*. Setelah dilakukan *differencing* 1 lag ACF yang dihasilkan pada Gambar 4.42(b) masih membentuk pola turun lambat sehingga akan dilakukan *differencing* lagi pada lag musiman 14. Dan setelah dilakukan *differencing* 1 dan 14, ACF dan PACF plot dapat dilihat pada gambar 4.42

Berdasarkan Gambar 4.43 dapat dikatakan data telah stasioner dalam mean karena pola ACF sudah *cut-off* pada lag 1. Langkah selanjutnya adalah dengan melakukan identifikasi model untuk ARIMA.



Gambar 4.43 (a) ACF Plot dan (b) PACF plot untuk Kota Banyuwangi Setelah *Differencing* 1 dan 14

Berdasarkan ACF pada Gambar 4.32(a), lag yang signifikan adalah lag 1,4,14 dan berdasarkan PACF pada gambar 4.32(b) lag yang signifikan adalah lag 1,2,3,5,6,14. Maka beberapa model ARIMA akan dapat dibentuk dari kombinasi lag yang signifikan pada ACF pada model MA dan PACF pada model AR dapat dilihat pada Tabel 4.17. Model tersebut akan dilakukan pengujian pada parameter dan residualnya. Berikut merupakan hasil yang didapatkan dari pengujian asumsi parameter signifikan, *white noise* dan distribusi Normal.

Dari Tabel 4.17 diatas, dapat diketahui bahwa model yang ditampilkan diatas merupakan model yang telah memenuhi asumsi parameter yang signifikan. Hal tersebut dapat diliha pada pengujian signifikansi parameter semua nilai p-value telah bernilai lebih kecil dari α . Kemudian terdapat dua model yang memenuhi asumsi *white noise*, $ARIMA([1,2,5,16],1,1)(0,1,1)^{14}$ dan $ARIMA([1,2,16],1,1)(3,1,0)^{14}$.

Tabel 4.19 Pengujian Asumsi Model ARIMA untuk Kota Banyuwangi

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ((1,2,16),1,1) (3,1,0) ¹⁴	θ_1	0,85093	<,0001	6	,	<0,01
	ϕ_1	0,27361	<,0001	12	0,0752	
	ϕ_2	0,14924	0,0018	18	0,1096	
	ϕ_{16}	0,11593	0,0011	24	0,0809	
	Φ_{14}	-0,72083	<,0001	30	0,0843	
	Φ_{28}	-0,50365	<,0001	36	0,1881	
	Φ_{42}	-0,22412	<,0001			
ARIMA ((1,2,5,16),1,1) (0,1,1) ¹⁴	θ_1	0,75849	<,0001	6	,	< 0,01
	Θ_{14}	0,82325	<,0001	12	0,3359	
	ϕ_1	0,19166	0,0054	18	0,6275	
	ϕ_2	0,10671	0,0437	24	0,3449	
	ϕ_5	-0,0879	0,0332	30	0,3952	
	ϕ_{16}	0,12773	0,0005	36	0,5575	
ARIMA ((1,2,3,5,16),1,0) (0,1,1) ¹⁴	Θ_{14}	0,83638	<,0001	6	,	<0,01
	ϕ_1	-0,51016	<,0001	12	0,0038	
	ϕ_2	-0,24758	<,0001	18	0,0695	
	ϕ_3	-0,16826	<,0001	24	0,1013	
	ϕ_5	-0,08121	0,0135	30	0,1492	
	ϕ_{16}	0,11769	0,0004	36	0,3194	

Informasi tersebut dapat diketahui dari tabel 4.19 kolom p-value untuk pengujian *white noise*, nilai p-value yang dihasilkan untuk setiap lag bernilai lebih besar dari α sehingga dapat dikatakan bahwa residual telah memenuhi asumsi *white noise*. Dari kedua model tersebut tidak ada model yang


memenuhi asumsi normalitas karena nilai p-value hasil uji KS bernilai kurang dari α yang artinya residual tidak berdistribusi normal. Sama halnya dengan kota lainnya, permodelan ARIMA akan dicoba dengan menggunakan ARIMA *outlier* dengan pengamatan ke 332, 287, 706 sebagai *additive outlier* dan pengamatan ke 26, 308 sebagai *shift outlier*. berikut merupakan hasil pengujian asumsi untuk model ARIMA *outlier*

Tabel 4.20 Pengujian Asumsi ARIMA *Outlier* untuk Kota Banyuwangi

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([3,16],1,1) (1,1,1) ¹⁴	θ_1	0,77732	<,0001	6	,	< 0,01
	Θ_{14}	0,82169	<,0001	12	0,1248	
	ϕ_1	0,22889	0,0015	18	0,3482	
	ϕ_2	0,13675	0,0116	24	0,3974	
	ϕ_5	-0,03723	0,3627	30	0,5494	
	ϕ_{16}	0,1774	<,0001	36	0,6931	
	AO ₁	-1,47749	<,0001			
	AO ₂	1,23821	<,0001			
	AO ₃	-1,24484	<,0001			
	LS ₁	1,2145	<,0001			
	LS ₂	-1,11426	<,0001			

Berdasarkan Tabel 4.20 dapat diketahui bahwa model dari ARIMA *outlier* tidak memberikan hasil yang lebih baik, hal tersendut diketahui dari hasil residual yang tetap tidak berdistribusi normal. nilai p-value untuk pengujian residual tetap bernilai lebih kecil dari α sehingga akan dilanjutkan ke melakukan peramalan pada data outsample. Berikut merupakan

plot hasil perbandingan antara data ramalan dengan data outsampel dari kota Banyuwangi.




Gambar 4.44 Plot Perbandingan antara Hasil Ramalan dan Outsampel Kota Banyuwangi menggunakan ARIMA.

Pola hasil ramalan ARIMA dari kota Banyuwangi memiliki hasil ramalan yang cukup baik karena nilai ramalan yang mendekati data asli. Meskipun pada akhir tahun 2016, hasil ramalan ARIMA tidak dapat *mengcover* data out sampel yang meningkat. Hasil nilai kebaikan modelnya adalah sebesar 4,83% untuk nilai sMAPE dan 444,23 untuk nilai RMSE.

4.2.9 Pemodelan Permintaan Beban Listrik di Kota Situbondo Menggunakan ARIMA


Sebelum melakukan Pemodelan menggunakan ARIMA, perlu dilihat pola data permintaan beban listrik dari kota Situbondo yang dapat dilihat pada time series plot pada gambar berikut. Gambar 4.45 merupakan time series plot untuk permintaan beban listrik kota Situbondo yang dibuat tanpa efek mingguan dan dengan efek mingguan. Dengan melihat time series plot dapat diketahui secara visual stasioneritas dalam mean dan varians. Dari Gambar 4.34 (a) dapat diketahui bahwa pola data sudah terlihat stasioner dalam mean karena data sudah bergerak naik turun di sekitar 3750 MW dan sudah stasioner dalam varians karena persebaran dari waktu ke waktu hampir

sama. Sedangkan, berdasarkan Gambar 4.34 (b) dapat diketahui bahwa pola permintaan beban di Situbondo tidak terpengaruh dari efek hari.



Gambar 4.45 Time Series Plot untuk Kota Situbondo (a) Regular dan (b) Berdasarkan Hari Selama 50 Hari


Hal tersebut diketahui dari tidak adanya perbedaan yang terlihat dari permintaan beban pada hari tertentu. Selain secara visual, stasioneritas dalam varians dapat diketahui dengan melihat hasil transformasi box-cox pada gambar berikut.



Gambar 4.46 Transformasi Box-Cox Kota Situbondo (a) Sebelum Transformasi (b) Setelah Transformasi

Data dapat dikatakan stasioner dalam varians jika nilai rounded lambda yang dihasilkan dari transformasi box-cox bernilai sama dengan satu atau interval dari batas atas dan bawahnya melalui angka satu. Dari Gambar 4.46 (a), dapat


diketahui bahwa nilai rounded lambda sama dengan satu dan intervalnya tidak melewati angka satu sehingga dapat dikatakan bahwa data tersebut belum stasioner dalam varians. Karena data belum stasioner dalam varians maka perlu dilakukan transformasi sesuai dengan nilai rounded lambda. Transformasi yang akan dilakukan adalah $Z_t = \ln(Y_t)$ dan kemudian dilakukan pengecekan ulang dengan menggunakan transformasi box-cox. Hasil transformasi tersebut dapat dilihat pada Gambar 4.46 (b). Nilai rounded lambda yang dihasilkan adalah sebesar sama dengan satu maka dapat dikatakan bahwa data telah stasioner dalam varians. Selanjutnya adalah melakukan pengecekan stasioneritas dalam mean dengan melihat pola dari ACF plot berikut.



Gambar 4.47 ACF Plot untuk Kota Situbondo (a) Sebelum *Differencing* dan (b) Setelah *Differencing* 1

Untuk melihat stasioneritas dalam mean dapat dilakukan dengan melihat plot ACF yang terbentuk. Jika plot ACF membentuk pola turun lambat maka dapat dikatakan data belum stasioner dalam mean. Berdasarkan Gambar 4.47 (a) dapat diketahui bahwa plot ACF membentuk pola yang turun lambat sehingga dapat dikatakan bahwa data belum stasioner dalam mean. Karena data belum stasioner dalam mean maka akan dilakukan differencing secara reguler. Setelah dilakukan differencing, dilihat kembali pola ACF yang terbentuk dari data

yang telah dilakukan differencing. Plot ACF tersebut dapat dilihat pada Gambar 4.47 (b). Dari gambar tersebut dapat diketahui bahwa data masih belum stasioner dalam mean karena ACF masih membentuk pola turun lambat sehingga akan dilakukan differencing pada lag musiman 14. Berikut merupakan hasil plot ACF dan PACF setelah dilakukan differencing pada lag 1 dan 14.



Gambar 4.48 (a) ACF Plot dan (b) PACF plot untuk Kota Situbondo Setelah *Differencing* 1 dan 14

Dari plot ACF diatas diketahui bahwa data sudah stasioner dalam mean karena plot ACF sudah tidak mmebentuk pola menurun secara lambat. Setelah diketahui data telah stasioner dalam mean dan varians, selanjutnya adalah melakukan identifikasi untuk membentuk model ARIMA. Identifikasi dapat dilakukan dengan melihat pola PACF untuk model AR dan pola ACF untuk model MA. Pada Gambar 4.48 (a), diketahui bahwa lag yang signifikan adalah lag ke 1,14,15 dan pada Gambar 4.48 (b) , lag yang signifikan terdapat pada lag 1,2,3,4,14,15,28,29. Maka model ARIMA yang mungkin terbentuk adalah sebagai berikut.

Dari Tabel 4.21 diatas dapat diketahui model ARIMA yang memenuhi asumsi pertama, yaitu semua parameter yang berpengaruh secara signifikan.

Tabel 4.21 Uji Signifikansi Model ARIMA Kota Situbondo

Model	Parameter	p-value
ARIMA(4,1,1)(2,1,1) ¹⁴	θ_1	-0,69762 0,4747
	Θ_{14}	-0,99722 <0,0001
	ϕ_1	-1,15548 0,2394
	ϕ_2	-0,49002 0,2905
	ϕ_3	-0,23716 0,2284
	ϕ_4	-0,07293 0,6268
	Φ_{14}	-1,33601 <0,0001
	Φ_{28}	-0,33601 0,0002
ARIMA([1,2,3,4,15],1,1)(2,1,1) ¹⁴	θ_1	0,96335 <0,0001
	Θ_{14}	0,89052 <0,0001
	ϕ_1	0,11321 0,0049
	ϕ_2	0,20043 <0,0001
	ϕ_3	0,03436 0,3866
	ϕ_4	0,10259 0,0096
	ϕ_{15}	-0,05688 0,1431
	Φ_{14}	0,0011575 0,9797
	Φ_{28}	0,0076159 0,8659
ARIMA(2,1,1)(0,1,1) ¹⁴	θ_1	0,95376 <0,0001
	Θ_{14}	0,89166 <0,0001
	ϕ_1	0,11729 0,0033
	ϕ_2	0,22005 <0,0001

Tabel 4.21 (Lanjutan)

Model	Parameter		p-value
ARIMA([1,2,4],1,1)(0,1,1) ¹⁴	θ_1	0,96807	<0,0001
	Θ_{14}	0,89017	<0,0001
	ϕ_1	0,12686	0,0012
	ϕ_2	0,20935	<0,0001
	ϕ_4	0,1155	0,0031
ARIMA([1,2,4,11],1,1)(0,1,1) ¹⁴	θ_1	0,95256	<0,0001
	Θ_{14}	0,89029	<0,0001
	ϕ_1	0,10955	0,0061
	ϕ_2	0,19613	<0,0001
	ϕ_4	0,10471	0,0075
	ϕ_{11}	-0,10337	0,0072

Tabel 4.21 Pengujian *White Noise* dan Distribusi Normal pada Model ARIMA Kota Situbondo

Model	<i>White Noise</i>		Uji Normalitas
	lag	p-value	p-value
ARIMA(2,1,1)(0,1,1) ¹⁴	6	0,002	<0,01
	12	0,0071	
	18	0,0137	
	24	0,0164	
	30	0,025	
	36	0,036	
ARIMA([1,2,4],1,1)(0,1,1) ¹⁴	6	0,0158	<0,01
	12	0,0762	
	18	0,1232	
	24	0,1135	
	30	0,1059	
	36	0,1304	

Tabel 4.21 (Lanjutan)

Model	White Noise		Uji Normalitas
	lag	p-value	p-value
ARIMA([1,2,4,11],1,1)(0,1,1) ¹⁴	6	,	
	12	0,4143	
	18	0,4147	
	24	0,2678	<0,01
	30	0,3004	
	36	0,3234	

Parameter berpengaruh secara signifikan jika nilai p-value lebih kecil dari nilai alfa ($\alpha = 0,05$). Dari kelima model diatas diketahui model yang seluruh parameternya berpengaruh secara signifikan adalah ARIMA (2,1,1)(0,1,1)¹⁴, ARIMA ([1,2,4],1,1) (0,1,1)¹⁴ dan ARIMA ([1,2,4,11],1,1) (0,1,1)¹⁴. Kemudian model-model tersebut akan dilakukan pengujian terhadap asumsi kedua yaitu residual berdistribusi Normal dan merupakan proses yang white noise. Yang dapat dilihat pada Tabel 4.21

Dari Tabel 4.21 diatas dapat diketahui model ARIMA yang memenuhi asumsi *white noise* adalah model ARIMA([1,2,4,11],1,1)(0,1,1)¹⁴, tetapi residualnya tidak berdistribusi Normal. Model dikatakan white noise jika nilai p-value, pada kolom white noise, bernilai lebih besar dari α dan residualnya berdistribusi normal jika p-value, pada kolom Uji Normalitas, bernilai lebih besar dari α . Dari semua model yang memenuhi asumsi parameter signifikan, tidak dapat memenuhi asumsi residual yang berdistribusi Normal. Hal tersebut dapat diketahui karena nilai p-value pada uji normalitas bernilai lebih kecil dari 0,01 yang artinya residual tidak berdistribusi normal. Salah satu upaya yang dapat dilakukan adalah memodelkan

dengan ARIMA outlier dan mendapatkan hasil seperti pada Tabel 4.21.


Pada model ARIMA([1,2,4,11],1,1)(0,1,1)¹⁴, outlier terjadi pada pengamatan ke 332,343,311,135 dan 712, dimana semua outlier tersebut merupakan Additive outlier. Dari tabel diatas, dapat diketahui bahwa pemodel dengan ARIMA outlier tidak menghasilkan hasil lebih baik karena residual masih tetap tidak berdistribusi Normal. Sama halnya dengan pemodelan ARIMA pada kota Surabaya, asumsi untuk residual berdistribusi normal akan tidak diperhatikan dan akan dilanjutkan pada pemodelan dengan menggunakan SVR.

Tabel 4.22 Pengujian Asumsi untuk Model ARIMA *Outlier* Kota Situbondo

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	lag	p-value	p-value
ARIMA([1,2,4,11],1,1)(0,1,1) ¹⁴	θ_1	0,87183	<,0001	6	<,0001	<0,01
	Θ_{14}	-0,68362	<,0001	12	<,0001	
	ϕ_3	-0,24503	<,0001	18	<,0001	
	ϕ_9	0,07463	0,0165	24	<,0001	
	Φ_{14}	-0,02074	0,5005	30	<,0001	
	AO ₁	-0,44233	<,0001	36	<,0001	
	AO ₂	0,25173	<,0001			
	AO ₃	0,22364	<,0001			
	AO ₄	0,24498	<,0001			
	AO ₅	-0,19715	<,0001			

Selanjutnya adalah melakukan peramalan pada data outsampel dan membandingkannya dengan data outsampel.

Berikut merupakan plot hasil perbandingan antara ramalan dan data outsampel.




Gambar 4.49 Plot Perbandingan Antara Data Outsampel kota Situbondo dan Hasil Ramalan dengan Menggunakan ARIMA

Berdasarkan plot hasil ramalan pada Gambar 4.49, diketahui bahwa hasil ramalan untuk Kota Situbondo merupakan ramalan yang baik karena nilai ramalannya mendekati data outsampel. Meskipun terdapat beberapa titik yang cukup tinggi atau rendah sehingga tidak dapat ditangkap oleh model ARIMA. Nilai kebaikan model yang dihasilkan adalah sebesar 5,32% untuk nilai sMAPE dan 246,64 untuk RMSE.


4.2.10 Pemodelan Permintaan Beban Listrik di Kota Mojokerto Menggunakan ARIMA

Langkah pertama yang akan dilakukan adalah melihat pola data melalui *time series plot* dari kota Mojokerto yang ditampilkan pada gambar 4.50. Berdasarkan Gambar 4.50(a) dapat diketahui bahwa pola data dari Mojokerto menyerupai pola data yang dimiliki Surabaya dan Sidoarjo. Berdasarkan pola tersebut dapat dikatakan bahwa data belum stasioner dalam mean dan varians, karena terdapat pengamatan-pengamatan yang terletak dibawah pengamatan yang lain.




Gambar 4.50 *Time Series Plot* untuk Kota Mojokerto (a) Reguler dan (b) Berdasarkan Hari

Dan berdasarkan Gambar 4.50(b), pola musiman mingguan juga dimiliki dari kota Mojokerto. Hal tersebut ditandai dengan adanya permintaan beban pada hari Minggu yang relatif lebih rendah dibandingkan dengan hari lainnya. Selanjutnya akan dilakukan pengecekan stasioneritas dalam varians dengan melihat hasil dari transformasi box-cox berikut.




Gambar 4.51 Transformasi Box-Cox Kota Mojokerto

Berdasarkan Gambar 4.51 dapat diketahui bahwa data telah stasioner dalam varians karena hasil transformasi box-cox menghasilkan *rounded lambda* sama dengan 5. Selanjutnya akan dilakukan pengecekan stasioneritas dalam mean dengan melihat pola pada plot ACF berikut.



Gambar 4.52 ACF Plot untuk Kota Mojokerto (a) Sebelum Differencing dan (b) Setelah Differencing 14



Gambar 4.53 (a) ACF Plot dan (b) PACF plot untuk Kota Mojokerto Setelah Differencing 14 dan 1

Pola ACF plot yang membentuk gelombang sinus teredam seperti pada Gambar 4.52(a) menandakan bahwa data telah stasioner dalam mean. Tetapi jika dilihat dari lag musiman 14, pola ACF memiliki nilai yang tinggi dan pola turun lambat, sehingga diperlukan *differencing* pada lag 14. Setelah dilakukan *differencing* pada lag 14, dilihat kembali plot ACF yang terbentuk pada Gambar 4.52(b). Pada gambar tersebut terdapat lag yang turun lambat, sehingga dikatakan data belum stasioner dalam mean dan akan dilakukan *differencing* pada lag 1. Berikut merupakan hasil plot ACF dan PACF yang terbentuk setelah *differencing* 1 dan 14

Dari Gambar 4.53(a) dapat diketahui bahwa data telah stasioner dalam mean, karena ACF plot telah *cut-off* setelah lag 1. Kemudian dilakukan identifikasi model ARIMA berdasarkan ACF dan PACF plot diatas dan menghasilkan model yang ditampilkan pada tabel 4.53. Berdasarkan Tabel 4.23, model yang yang diberikan merupakan model yang telah memenuhi asumsi parameter signifikan, karena nilai p-value untuk parameter tiap model memiliki nilai yan lebih kecil dari α .

Tabel 4.23 Pengujian Asumsi ARIMA untuk Kota Mojokerto

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,3,8,10],1,1) (3,1,0) ¹⁴	θ_1	0,24974	0,0002	6	-	< 0,01
	ϕ_1	-0,22643	0,0013	12	0,7605	
	ϕ_3	-0,17287	0,0001	18	0,6366	
	ϕ_8	0,093	0,0096	24	0,7233	
	ϕ_{10}	0,1045	0,0042	30	0,4544	
	Φ_{14}	-0,66904	0,0001	36	0,3901	
	Φ_{28}	-0,44206	0,0001			
	Φ_{42}	-0,13667	0,0004			
ARIMA ([3,16,30],1,1) (1,1,1) ¹⁴	θ_1	0,42907	<,0001	6	,	< 0,01
	Θ_{14}	0,80281	<,0001	12	<,0001	
	ϕ_3	0,15482	<,0001	18	<,0001	
	ϕ_{16}	0,10217	0,0066	24	<,0001	
	ϕ_{30}	0,12126	0,0013	30	<,0001	
	Φ_{14}	0,06103	0,2117	36	<,0001	

Dari kedua model tersebut hanya model ARIMA([1,3,8,10],1,1)(3,1,0)¹⁴ yang memenuhi asumsi *white noise*. Dari kedua model tersebut juga tidak memenuhi asumsi normalitas karena nilai p-value dari uji KS bernilai lebih kecil dari α , yang artinya residual tidak berdistribusi normal. Karena


residual tidak berdistribusi normal maka dapat dilakukan pemodelan ARIMA *outlier* untuk mengatasi ketidak normal yang diduga akibat adanya *outlier*. Hasil pengujian asumsi dari ARIMA *outlier* dapat dilihat pada Tabel 4.24

Tabel 4.24 Pengujian Asumsi untuk ARIMA *Outlier* kota Mojokerto

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,3,8,10],1,1) (3,1,0) ¹⁴	θ_1	0,18497	0,0096	6	,	< 0,01
	ϕ_1	-0,33852	<,0001	12	0,4048	
	ϕ_3	-0,12025	0,001	18	0,0601	
	ϕ_8	0,10885	0,0021	24	0,1134	
	ϕ_{10}	0,07667	0,0341	30	0,1432	
	Φ_{14}	-0,66612	<,0001	36	0,0873	
	Φ_{28}	-0,43116	<,0001			
	Φ_{42}	-0,1201	0,002			
	AO ₁	-0,87646	<,0001	6	,	
	AO ₂	-0,8065	<,0001	12	<,0001	
	AO ₃	-0,64842	<,0001	18	<,0001	
	AO ₄	-0,57029	<,0001	24	<,0001	
	LS ₁	-0,57945	<,0001	30	<,0001	

Berdasarkan Tabel 4.23 dapat diketahui bahwa model ARIMA *outlier* tidak memberikan hasil yang lebih baik karena hasil residualnya masih tidak berdistribusi normal. Pengamatan yang diduga sebagai *outlier* adalah pengamatan ke 511,459,694,77 sebagai *additive outlier* dan 371 sebagai *shift outlier*. Karena residual tetap tidak dipenuhi asumsinya maka akan dilanjutkan ke peramalan pada data outsampel.


Dari model ARIMA yang memenuhi asumsi *white noise* akan dilakukan peramalan pada data *outsample*. Berikut merupakan plot perbandingan antara data outsample dengan hasil ramalannya yang ditampilkan pada Gambar 4.43. Berdasarkan Gambar 4.43 dapat diketahui bahwa hasil ramalan dari kota Mojokerto kurang baik karena hasil ramalannya yang tidak mendekati nilai dari data outsample, meskipun pola yang dimiliki sudah menyerupai dari data outsample. Nilai kebaikan model yang dihasilkan adalah sebesar 53,71% untuk nilai sMAPE dan 10862,86 untuk RMSE.



Gambar 4.54 Perbandingan Pola hasil Ramalan dan Outsample dari Kota Mojokerto


4.2.11 Pemodelan Permintaan Beban Listrik di Kota Kediri Menggunakan ARIMA

Langkah pertama yang dilakukan adalah melihat pola data melalui *time series plot* dari permintaan beban kota Kediri.



Gambar 4.55 *Time Series Plot* untuk Kota Kediri


Berdasarkan Gambar 4.55 dapat dikatakan bahwa pola dari permintaan beban listrik di Kediri memiliki pola yang belum stasioner dalam mean dan varians. Karena terdapat beberapa pengamatan yang lebih rendah dibandingkan dengan pengamatan yang lainnya. Selanjutnya akan dilakukan pengecekan stasioneritas dalam varians dengan melihat hasil dari transformasi box-cox. Berikut merupakan hasil dari transformasi box-cox yang dapat dilihat pada Gambar 4.56



Gambar 4.56 Transformasi Box-Cox Kota Kediri (a) Sebelum Transformasi (b) Setelah Transformasi


Karena nilai *rounded lambda* bernilai sama dengan 0,5 pada Gambar 4.56(a), maka dapat dikatakan bahwa data belum stasioner dalam varians sehingga perlu dilakukan transformasi dimana nilai $Y_t = Z_t^{0.5}$. Kemudian setelah dilakukan transformasi box-cox lagi, nilai rounded lambda sama dengan 1, seperti dapat dilihat pada Gambar 4.56(b). kemudian akan dilakukan

pengecekan stasioneritas dalam mean dengan melihat pola dari ACF berikut



Gambar 4.57 ACF Plot untuk Kota Kediri (a) Sebelum *Differencing* dan (b) Setelah *Differencing* 1

Berdasarkan Gambar 4.57(a) dapat diketahui bahwa data belum stasioner dalam mean karena pola dari plot ACF membentuk pola turun lambat. Karena data belum stasioner dalam mean maka akan dilakukan *differencing* pada lag 1 dan menghasilkan plot ACF pada Gambar 4.57(b). Berdasarkan pola ACF pada gambar tersebut, data masih belum stasioner dalam mean sehingga akan dilakukan *differencing* pada lag 1 dan 14. Berikut merupakan plot ACF dan PACF hasil *differencing* pada lag 1 dan 14.



Gambar 4.58 (a) ACF Plot dan (b) PACF plot untuk Kota Kediri Setelah *Differencing* 1 dan 14

Berdasarkan Gambar 4.58(a), plot ACF telah membentuk pola *cut-down* setelah lag ke 1 sehingga dapat dikatakan bahwa data telah stasioner dalam mean. Karena data telah stasioner

dalam mean dan varians maka langkah selanjutnya adalah melakukan identifikasi untuk membentuk model ARIMA. Identifikasi dilakukan dengan melihat lag yang signifikan dari ACF untuk membentuk model MA, dan lag yang signifikan dari PACF untuk membentuk model AR. Beberapa model yang terbentuk dapat dilihat pada Tabel 4.25

Tabel 4.25 Pengujian Asumsi untuk ARIMA kota Kediri

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([2,3,18],1,1) (3,1,0) ¹⁴	θ_1	0,71013	0,0001	6	-	< 0,01
	ϕ_2	0,16185	0,0003	12	0,1082	
	ϕ_3	-0,10738	0,0095	18	0,3682	
	ϕ_{18}	0,07523	0,0451	24	0,2601	
	Φ_{14}	-0,74269	0,0001	30	0,1185	
	Φ_{28}	-0,47462	0,0001	36	0,0976	
	Φ_{42}	-0,2543	0,0001			
ARIMA ([1,2,3,4,5,7,40],1,1) ,1,0)(0,1,1) ¹⁴	Θ_{14}	0,82312	<,0001	6	,	< 0,01
	ϕ_1	-0,63749	<,0001	12	0,0201	
	ϕ_2	-0,25621	<,0001	18	0,0193	
	ϕ_3	-0,23902	<,0001	24	0,028	
	ϕ_4	-0,11283	0,0121	30	0,0028	
	ϕ_5	-0,11154	0,0032	36	0,0017	
	ϕ_7	-0,06381	0,0442			
	ϕ_{40}	0,07947	0,0126			
ARIMA ([2,3],1,1) (2,1,0) ¹⁴	θ_1	0,71499	<,0001	18	0,144	< 0,01
	ϕ_2	0,13972	0,0018		0,4006	
	ϕ_3	-0,11192	0,007		0,2446	
	Φ_{14}	-0,67388	<,0001		0,1354	
	Φ_{28}	-0,30711	<,0001	24	0,0029	
				30	0,004	

Berdasarkan Tabel 4.26 model ARIMA yang tertera pada tabel merupakan model ARIMA yang telah memenuhi asumsi signifikan parameter. Hal itu diketahui dari nilai p-value pada

kolom uji signifikansi. Dari ketiga model tersebut hanya satu model yang memenuhi asumsi residual yang *white noise* yaitu ARIMA([2,3,18],1,1)(3,1,1)¹⁴. Meskipun model tersebut memenuhi asumsi *white noise*, dari ketiga model tidak ada yang memenuhi asumsi residual yang normal. kemudian akan dicoba memodelkan model diatas dengan menggunakan ARIMA *outlier*.


Tabel 4.26 Pengujian Asumsi untuk ARIMA *Outlier* kota Kediri

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([2,3,18],1,1) (3,1,0) ¹⁴	θ_1	0,7023	<,0001	6	,	< 0,01
	ϕ_2	0,20371	<,0001	12	0,028	
	ϕ_3	-0,07457	0,0749	18	0,1137	
	ϕ_{18}	0,0054273	0,8852	30	0,2084	
	Φ_{14}	-0,73537	<,0001	36	0,0208	
	Φ_{28}	-0,43509	<,0001			
	Φ_{42}	-0,21414	<,0001			
	AO ₁	-15,06237	<,0001			
	AO ₂	-14,88965	<,0001			
	AO ₃	-11,75898	<,0001			
	AO ₄	-12,29399	<,0001			
	AO ₅	-9,2709	<,0001			

Tabel 4.27 merupakan hasil pengujian asumsi pada ARIMA *outlier* dari kota Kediri dengan pengamatan ke

198,102,511,700 dan 375 sebagai *additive outlier*. Hasil dari pemodelan *outlier* tidak cukup baik karena residual masih tetap tidak berdistribusi normal. Maka akan dilanjutkan ke tahap berikutnya yaitu meramalkan berdasarkan data *outsample*.


Pada Gambar 4.59 dapat diketahui pola dari hasil ramalan pada data outsample untuk kota Kediri, memiliki hasil yang sama dengan kota seperti Surabaya dan lainnya. Hasil ramalan memiliki pola yang menyerupai data outsample tetapi nilai ramalannya tidak sesuai dengan data outsamplenya. Nilai kebaikan model yang dihasilkanpun cukup besar, yaitu 15,46% untuk sMAPE dan 2724,18 untuk RMSE. Dengan nilai sMAPE sebesar 15%, artinya tingkat kesalahan yang dibentuk dari hasil ramalan adalah sebesar 15%.



Gambar 4.59 Plot Hasil Perbandingan Antara Data Outsample dan Ramalan Kota Kediri Menggunakan ARIMA


4.2.12 Pemodelan Permintaan Beban Listrik di Kota Bojonegoro Menggunakan ARIMA

Langkah pertama yang dilakukan adalah melihat pola data melalui *time series plot* dari permintaan beban kota Bojonegoro.




Gambar 4.60 *Time Series Plot* untuk Kota Bojonegoro

Berdasarkan Gambar 4.60 dapat dikatakan bahwa pola dari permintaan beban listrik di Bojonegoro memiliki pola yang belum stasioner dalam mean dan varians. Karena terdapat beberapa pengamatan yang lebih rendah dibandingkan dengan pengamatan yang lainnya. Selanjutnya akan dilakukan pengecekan stasioneritas dalam varians dengan melihat hasil dari transformasi box-cox. Berikut merupakan hasil dari transformasi box-cox yang dapat dilihat pada Gambar 4.61




Gambar 4.61 Transformasi Box-Cox Kota Bojonegoro (a) Sebelum Transformasi (b) Setelah Transformasi

Berdasarkan transformasi box-cox pada Gambar 4.61(a) diatas nilai *rounded lambda* adalah sama dengan 0,5. Maka data akan ditransformasikan dengan dipangkatkan setengah. Kemudian dilakukan transformasi box-cox lagi dan menghasilkan *rounded lambda* yang batas atas dan bawah telah melewati angka 1. Kemudian akan dilakukan pengecekan stasioneritas dalam mean dengan melihat pola ACF yang terdapat pada gambar 4.62 berikut. Berdasarkan Gambar 4.62(a) diketahui bahwa data tidak stasioner dalam mean karena pola dari ACF plot membentuk pola turun lambat sehingga data perlu dilakukan *differencing* pada lag 1. Setelah dilakukan *differencing*, plot ACF yang terbentuk pada Gambar 4.62(b) memiliki pola yang turun lambat sehingga akan dilakukan *differencing* pada lag 14. Berikut merupakan hasil plot ACF dan PACF setelah *differencing* pada lag 1 dan 14.



Gambar 4.62 ACF Plot untuk Kota Bojonegoro (a) Sebelum *Differencing* dan (b) Setelah *Differencing* 1

Berdasarkan Gambar 4.63 dapat diketahui bahwa data telah stasioner dalam mean. langkah selanjutnya adalah melakukan pemodelan dengan menggunakan plot ACF dan PACF untuk mengidentifikasi model MA dan AR. Pada tabel 4.27 akan ditampilkan model ARIMA yang telah memenuhi asumsi lag yang telah signifikan.



Gambar 4.63 (a) ACF Plot dan (b) PACF plot untuk Kota Bojonegoro Setelah *Differencing* 1 dan 14

Tabel 4.27 Pengujian Asumsi untuk ARIMA kota Bojonegoro

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,2,4,6,15,30], 0,0)(0,1,1) ¹⁴	Θ_{14}	0,82303	<,0001	6	,	< 0,01
	ϕ_1	0,30449	<,0001	12	0,419	
	ϕ_2	0,21564	<,0001	18	0,1739	
	ϕ_4	0,13458	0,0003	24	0,4047	
	ϕ_6	0,13295	0,0002	30	0,589	
	ϕ_{15}	-0,07783	0,0113	36	0,6076	
	ϕ_{30}	0,08361	0,0061			
ARIMA ([3,6,15,30],1,1) (2,1,0) ¹⁴	θ_1	0,61207	<,0001	6	,	< 0,01
	ϕ_3	-0,1289	0,0011	12	0,064	
	ϕ_6	0,07905	0,035	18	0,2343	
	ϕ_{15}	-0,09044	0,0155	24	0,5259	
	ϕ_{30}	0,08679	0,0204	30	0,0375	
	Φ_{14}	-0,59525	<,0001	36	0,0365	
	Φ_{28}	-0,29135	<,0001			


Pada Tabel 4.28 merupakan hasil pemodelan dengan menggunakan ARIMA yang telah memenuhi asumsi signifikan dalam parameter. Dari kedua model tersebut hanya terdapat satu model yang memenuhi asumsi *white noise*, yaitu adalah model ARIMA([1,2,4,6,15,30],0,0)(0,1,1)¹⁴. Dari kedua model tersebut tidak ada yang memenuhi asumsi residual yang normal sehingga model diatas akan dimodelkan dengan menggunakan ARIMA *outlier*.

Tabel 4.28 Pengujian Asumsi untuk ARIMA kota Bojonegoro

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA([2,3,18],1,1)(3,1,0) ¹⁴	θ_1	0,80917	<,0001	6	,	< 0,01
	ϕ_2	0,32271	<,0001	12	0,0689	
	ϕ_3	0,22801	<,0001	18	0,2744	
	ϕ_{18}	0,13529	0,0003	24	0,4688	
	Φ_{14}	0,14646	<,0001	30	0,3818	
	Φ_{28}	-0,08093	0,0062	36	0,3706	
	Φ_{42}	0,06579	0,0247			
	AO ₁	-15,26149	<,0001			
	AO ₂	-13,48295	<,0001			
	AO ₃	-10,66704	<,0001			
	AO ₄	-9,15595	<,0001			
	AO ₅	-8,36566	<,0001			

Berdasarkan Tabel 4.28, model ARIMA dengan *outlier* tidak memberikan hasil lebih baik karena residual masih berdistribusi tidak normal. Hasil dari pemodelan ARIMA yang ditambahkan dengan *outlier* tetap tidak membuat residual yang


dihasilkan berdistribusi normal. Plot hasil ramalan dapat dilihat pada Gambar 4.53.



Gambar 4.64 Plot Perbandingan Antara Hasil Ramalan dan Outsample Kota Bojonegoro

4.2.13 Pemodelan Permintaan Beban Listrik di Kota Madiun Menggunakan ARIMA


Langkah pertama yang dilakukan adalah melihat pola data melalui *time series plot* dari permintaan beban kota Madiun.



Gambar 4.65 *Time Series Plot* untuk Kota Madiun


Berdasarkan Gambar 4.65 dapat dikatakan bahwa pola dari permintaan beban listrik di Madiun memiliki pola yang belum stasioner dalam mean dan varians. Karena terdapat beberapa pengamatan yang lebih rendah dibandingkan dengan

pengamatan yang lainnya. Selanjutnya akan dilakukan pengecekan stasioneritas dalam varians dengan melihat hasil dari transformasi box-cox. Berikut merupakan hasil dari transformasi box-cox yang dapat dilihat pada Gambar 4.66




Gambar 4.66 Transformasi Box-Cox Kota Madiun (a) Sebelum Transformasi (b) Setelah Transformasi

Berdasarkan hasil transformasi box-cox pada Gambar 4.66(a), nilai *rounded lambda* bernilai sama dengan 0 sehingga dapat dikatakan bahwa data belum stasioner dalam varians. Maka data akan di transformasi dengan \ln dan kemudian di transformasi dengan box-cox lagi. Pada Gambar 4.66(b) hasil *rounded lambda* telah memiliki batas atas dan bawah yang melewati angka 1 sehingga dikatakan bahwa data telah stasioner dalam varians. kemudian dilakukan pengecekan stasioneritas dalam mean dengan melihat pola pada ACF plot berikut.




(a)



(b)

Gambar 4.67 ACF Plot untuk Kota Madiun (a) Sebelum *Differencing* dan (b) Setelah *Differencing* 1

Berdasarkan Gambar 4.67(a) ACF plot memiliki pola turun lambat sehingga dapat dikatakan bahwa data belum stasioner dalam mean. kemudian setelah dilakukan *differencing*, pola ACF pada Gambar 4.67(b) tetap membentuk pola yang turun lambat sehingga akhirnya dilakukan *differencing* pada lag ke 14. Berikut merupakan hasil plot ACF dan PACF setelah dilakukan *differencing* pada lag 1 dan 14. Berdasarkan ACF plot yang terbentuk pada Gambar 4.68 dapat diketahui bahwa data telah stasioner dalam mean karena pola ACF sudah *cut off* pada lag pertama. Karena telah diketahui data telah stasioner dalam mean dan varians, langkah selanjutnya adalah melakukan identifikasi model ARIMA berdasarkan plot pada Gambar 4.68.



Gambar 4.68 (a) ACF Plot dan (b) PACF plot untuk Kota Madiun Setelah *Differencing* 1 dan 14


Tabel 4.29 Pengujian Asumsi pada Model ARIMA kota Madiun

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,2,4,6],1,1) (3,1,0) ¹⁴	θ_1	0,89906	0,0001	6	-	< 0,01
	ϕ_1	0,17547	0,0267	12	0,1652	
	ϕ_2	0,19488	0,0013	18	0,4628	
	ϕ_4	0,15097	0,0025	24	0,6593	
	ϕ_6	0,12617	0,0025	30	0,2621	
	Φ_{14}	-0,7012	0,0001	36	0,1793	
	Φ_{28}	-0,43986	0,0001			
	Φ_{42}	-0,20381	0,0001			

Berdasarkan tabel 4.28 model ARIMA merupakan model terbaik dari model-model lain. Model diatas merupakan model yang memenuhi asumsi signifikan parameter dan *white noise* tetapi tidak pada asumsi normal. Tetapi residual tetap tidak normal setelah dimodelkan dengan *outlier*. Kebaikan model yang dihasilkan model ini adalah sebesar 8,10% dan 746,24 untuk sMAPE dan RMSE. Plot hasil ramalan dapat dilihat pada gambar 4.69.

Tabel 4.30 Pengujian Asumsi pada Model ARIMA *Outlier* Kota Madiun


Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA([1,2,4,6],1,1)(3,1,0) ¹⁴	θ_1	0,86353	<,0001	6	,	< 0,01
	ϕ_1	0,12622	0,1545	12	0,0507	
	ϕ_2	0,24809	0,0002	18	0,1762	
	ϕ_4	0,08652	0,075	24	0,3747	
	ϕ_6	0,09945	0,0181	30	0,1243	
	Φ_{14}	-0,69128	<,0001	36	0,1832	
	Φ_{28}	-0,44904	<,0001			
	Φ_{42}	-0,21638	<,0001			
	AO ₁	-4,26101	<,0001			
	AO ₂	-3,33148	<,0001			
	AO ₃	-2,88218	<,0001			
	AO ₄	-3,01013	<,0001			
	AO ₅	-2,72473	<,0001			



Gambar 4.69 Plot Perbandingan Antara Hasil Ramalan dan Data Outsamle Kota Madiun


4.2.14 Pemodelan Permintaan Beban Listrik di Kota Ponorogo Menggunakan ARIMA

Langkah pertama yang dilakukan adalah melihat pola data melalui *time series plot* dari permintaan beban kota Ponorogo.




Gambar 4.70 *Time Series Plot* untuk Kota Ponorogo

Berdasarkan Gambar 4.59 dapat dikatakan bahwa pola dari permintaan beban listrik di Ponorogo memiliki pola yang belum stasioner dalam mean dan varians. Karena terdapat beberapa pengamatan yang lebih rendah dibandingkan dengan pengamatan yang lainnya. Selanjutnya akan dilakukan pengecekan stasioneritas dalam varians dengan melihat hasil dari transformasi box-cox.




Gambar 4.71 Transformasi Box-Cox Kota Ponorogo (a) Sebelum Transformasi (b) Setelah Transformasi

Berdasarkan hasil transformasi box-cox pada Gambar 4.60(a) dapat diketahui bahwa data belum stasioner dalam varians karena nilai *rounded lambda* sama dengan nol. Karena data belum stasioner dalam varians, maka data akan ditransformasi dengan \ln dan dilakukan transformasi box-cox lagi. Dan hasil yang didapatkan dapat dilihat pada Gambar 4.60(b), nilai batas atas dan bawah *rounded lambda*, sudah melewati angka 1. Selanjutnya akan dilakukan pengecekan stasioneritas dalam mean melalui plot ACF berikut.



Gambar 4.72 ACF Plot untuk Kota Ponorogo (a) Sebelum *Differencing* dan (b) Setelah *Differencing* 1

Berdasarkan ACF plot yang terbentuk pada Gambar 4.72(a), data dikatakan belum stasioner dalam mean karena pola dari ACF membentuk pola yang turun lambat. Kemudian data dilakukan *differencing* pada lag 1 dan menghasilkan ACF plot pada Gambar 4.72(b). Dari plot tersebut juga diketahui bahwa pola ACF masih turun lambat sehingga dilakukan *differencing* lagi pada lag 14. Berikut merupakan hasil plot ACF dan PACF pada data setelah *differencing* pada lag 1 dan 14.



Gambar 4.73 (a) ACF Plot dan (b) PACF plot untuk Kota Ponorogo Setelah *Differencing* 1 dan 14


Berdasarkan Gambar 4.73 dapat diketahui bahwa data telah stasioner dalam mean karena plot ACF sudah tidak membentuk pola turun lambat. Karena data sudah stasioner dalam mean dan varians maka langkah selanjutnya adalah melakukan identifikasi pada model ARIMA. Pada Tabel 4.31 merupakan hasil pengujian asumsi untuk model ARIMA dan hanya model tersebut yang merupakan model terbaik yang memenuhi asumsi hingga *white noise*

Tabel 4.31 Pengujian Asumsi pada Model ARIMA Kota Ponorogo

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,4,5,7,30],1,1) (0,1,1) ¹⁴	θ_1	0,8095	0,0001	6	-	< 0,01
	Θ_{14}	0,87123	0,0001	12	0,1509	
	ϕ_1	-0,10842	0,0146	18	0,3924	
	ϕ_4	0,09135	0,0239	24	0,2853	
	ϕ_4	-0,08324	0,0299	30	0,4022	
	ϕ_7	-0,10333	0,0059	36	0,4584	
	ϕ_{30}	0,12139	0,0012			

Tabel 4.32 Pengujian Asumsi pada Model ARIMA *Outlier* Kota Ponorogo

Model	Signifikansi Parameter			White Noise		Uji Normalitas
	Parameter	Nilai	p-value	Lag	p-value	p-value
ARIMA ([1,5,7,30],1,1) (0,1,1) ¹⁴	θ_1	0,95691	<,0001	6	,	< 0,01
	Θ_{14}	0,83309	<,0001	12	<,0001	
	ϕ_1	1,07593	<,0001	18	<,0001	
	ϕ_5	0,10908	0,0174	24	<,0001	
	ϕ_4	-0,21498	<,0001	30	<,0001	
	ϕ_7	0,02646	0,3629	36	<,0001	
	ϕ_{30}	-0,01307	0,0198			
	AO ₁	0,31615	<,0001			
	AO ₂	-0,2256	<,0001			
	AO ₃	0,22512	<,0001			
	AO ₄	-0,23476	<,0001			
	AO ₅	0,22514	<,0001			



Gambar 4.74 Plot Hasil Ramalan dan Data Outsampel Kota Ponorogo

Berdasarkan Tabel 4.32 pemodelan dengan menggunakan ARIMA *outlier* tidak memperbaiki hasil karena residual tetap tidak berdistribusi normal. Kemudian hasil ramalan untuk outsample dapat dilihat pada Gambar 4.74. Nilai kebaikan model yang dihasilkan adalah sebesar 10,18% dan 623,24 untuk sMAPE dan RMSE.

4.3 Pemodelan Permintaan Beban Listrik dengan Menggunakan SVR

Pemodelan permintaan beban listrik juga akan dilakukan dengan menggunakan metode lain, yaitu Support Vector Regresion. Fungsi kernel yang digunakan dalam peramalan dengan SVR adalah Gaussian (RBF). Dalam SVR memerlukan Support Vector yang digunakan untuk membentuk model. Support Vector yang digunakan dalam penelitian ini merupakan input dari lag-lag yang signifikan dari model ARIMA. Analisis dan pembahasan pada metode ARIMA akan dilakukan pada kota Surabaya yang merupakan kota dengan permintaan beban listrik tertinggi. Untuk kota atau kabupaten lain akan ditampilkan model SVR yang digunakan dan nilai kebaikan modelnya.

Sebelum dilakukan pemodelan dengan menggunakan SVR, perlu dilakukan pengujian Terasvirta untuk melihat linearitas pada data. Hasil pengujian Terasvirta untuk 14 kota dapat dilihat pada Tabel 4.32.

Pengujian Terasvirta dilakukan pada tiap kota dengan lag yang berbeda. Lag yang digunakan merupakan lag 1 hingga 10. Berdasarkan Tabel 4.32 dapat diketahui bahwa nilai *p-value* hasil pengujian Terasvirta bernilai kurang dari 0,05 sehingga dapat disimpulkan bahwa data tersebut memiliki pola yang non-linier.

Tabel 4.33 *P-Value* Hasil Uji Terasvirta pada 14 Kota

Kota	Lag											
	1	2	3	4	5	6	7	8	9	10	11	12
SBY	0,0009	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
MLG	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
GSK	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
SDA	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
PKS	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
BWG	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
JBR	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
STB	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
MDN	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
BJG	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
MIJ	0,0762	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
PNG	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0010	0,0001	0,0000	0,0000
KDR	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
PSR	0,0070	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

4.3.1 Pemodelan Beban Listrik Menggunakan SVR untuk Kota Surabaya

Hal pertama yang perlu dilakukan adalah mendapatkan lag-lag yang digunakan sebagai input untuk SVR dari metode ARIMA yang parameternya berpengaruh secara signifikan. Lag tersebut didapatkan dengan cara menjabarkan model ARIMA. Berdasarkan subbag 4.2.1 model ARIMA yang terpilih untuk kota Surabaya adalah ARIMA ([3,9],1,1)(1,0,1)₁₄. Model tersebut akan dijabarkan seperti berikut.


$$Z_t(\phi_1 B^1 - \phi_2 B^2 - \phi_3 B^3 - \phi_4 B^{43} - \phi_5 B^{52})(1-B)(1-\Phi_1 B^{14}) = a_t(1-\Theta_1 B^{14})$$

Dari persamaan diatas maka dapat diketahui lag-lag yang akan digunakan sebagai input dalam SVR. Input lag yang akan digunakan adalah Z_{t-1} , Z_{t-3} , Z_{t-4} , Z_{t-9} , Z_{t-10} , Z_{t-14} , Z_{t-15} , Z_{t-17} , Z_{t-18} , Z_{t-23} , dan Z_{t-24} . Setelah diketahui lag-lag yang signifikan pada model ARIMA maka dibentuk Support Vector yang terbentuk dari lag tersebut. Kemudian beberapa data pertama akan dihapus sesuai dengan jumlah lag terbesar. Pada kota Surabaya berikut lag terbesar adalah 24 maka 24 data pertama akan dihapus karena pada

Support Vector lag ke 24 akan bernilai kosong (*) pada 24 data pertama tersebut.

Dalam SVR, fungsi kernel Gaussian (RBF) memiliki tiga parameter dalam modelnya, yaitu cost (c), gamma (γ) dan epsilon (ξ). Untuk mendapatkan hasil parameter perlu dilakukan pemilihan parameter secara tepat. Dalam metode SVR terdapat metode optimasi didalamnya yang disebut dengan metode Grid Search. Metode Grid Search melakukan pemodelan dengan menggunakan SVR dengan range parameter tertentu. Parameter yang digunakan dilakukan secara bertahap dengan merubah parameternya selama di dalam range. Range parameter yang digunakan dalam penelitian ini adalah $\{(10^{-4}:10), (10^{-4}:4), (10^{-4}:1)\}$ secara berturut-turut untuk parameter cost, gamma, epsilon.

Berdasarkan hasil, nilai parameter optimum yang didapatkan adalah 9,001 untuk cost, 10^{-4} untuk gamma dan 10^{-4} untuk epsilon. Setelah didapatkan model maka dapat dilakukan Pemodelan untuk dua bulan kedepan. Hasil ramalan tersebut akan dibandingkan dengan data out-sample dan dihitung nilai akurasi. Berikut merupakan hasil perbandingan antara ramalan dengan menggunakan metode SVR dan data out-sample.



Gambar 4.75 Plot Perbandingan Hasil Ramalan SVR dengan Data Outsampel untuk Kota Surabaya

Berdasarkan Gambar 4.75 dapat dilihat kebaikan hasil ramalan model SVR. Ramalan dikatakan baik jika memiliki pola dan nilai yang mendekati data aslinya. Hasil ramalan metode SVR dapat dikatakan baik karena memiliki pola dan nilai yang mendekati data *outsampleny*. Jika dibandingkan hasil ramalan milik ARIMA, hasil ramalan SVR menghasilkan hasil yang lebih baik. Nilai kebaikan model atau akurasinya adalah sebesar 5,461% untuk SMAPE dan 4265,18 untuk RMSE. Model diatas merupakan model SVR berdasarkan model ARIMA yang memenuhi asumsi hingga *white noise*. Karena SVR merupakan metode yang bebas asumsi, maka dapat dimodelkan dengan menggunakan model ARIMA yang hanya memenuhi asumsi signifikansi parameter. Asumsi signifikansi parameter tetap dibutuhkan karena model SVR membentuk *support vector* dari model ARIMA. Berikut merupakan nila kebaikan model SVR dari beberapa model ARIMA yang memenuhi signifikansi parameter.

Tabel 4.34 Nilai Kebaikan Model SVR Kota Surabaya

Model	Lag	SMAPE	RMSE
ARIMA(1,1,0)(2,1,1) ¹⁴	1,2,14,15,16,28,29,30,42,43, 44	3,96%	3266,67
ARIMA(1,1,1)(2,0,0) ¹⁴	1,2,14,15,16,28,29,30	4,90%	3894,54
ARIMA ([3,9],1,1)(1,0,1) ¹⁴	1,3,4,9,10,14,15,17,18,23,24	5,46%	4265,18

Dari Tabel 4.34 dapat diketahui lag mana saja yang berpengaruh secara signifikan pada model ARIMA dan kemudian digunakan sebagai support vector pada metode SVR. Pada baris pertama dan kedua merupakan model ARIMA yang hanya memenuhi asumsi signifikan. Dan dilihat dari nilai kebaikan modelnya, SVR dengan menggunakan support vector dari ARIMA yang memenuhi asumsi signifikan saja memiliki nilai lebih tinggi jika dibandingkan menggunakan ARIMA yang memenuhi asumsi *white noise* dan parameter signifikan. Jadi dapat disimpulkan bahwa metode SVR memiliki nilai kebaikan model lebih tinggi jika menggunakan support vector dari model ARIMA yang memenuhi asumsi parameter signifikan saja.

4.3.2 Pemodelan Beban Listrik Menggunakan SVR untuk Kota Lainnya

Untuk mendapatkan hasil ramalan dengan menggunakan SVR pada kota lain, dapat dilakukan dengan mengikuti tahapan yang sama untuk memodelkan SVR pada kota Surabaya. Model ARIMA dan lag yang digunakan pada pemodelan kota lainnya dapat dilihat pada lampiran 3. Berikut merupakan nilai kebaikan model dari model SVR di setiap kota dan kabupatennya.

Tabel 4.35 Hasil Kebaikan Model SVR untuk Setiap Kota dan Kabupatennya

KOTA	SMAPE			RMSE		
	SVR1	SVR2	SVR3	SVR1	SVR2	SVR3
SBY	3,96%	4,90%	5,46%	3266,67	3894,54	4265,18
MLG	3,13%	3,29%	3,989%	761,14	771,92	927,32
GSK	6,24%	5,96%	5,96%	1067,66	1026,67	1026,67
SDA	9,60%	7,21%	9,60%	2773,58	2155,60	2773,58
PKS	5,06%	5,33%	5,33%	718,32	733,03	733,03
BWG	5,76%	6,07%	6,28%	498,96	526,38	538,06
JBR	5,03%	5,16%	5,03%	588,76	704,16	588,76
STB	4,43%	4,49%	4,47%	230,46	225,94	222,85
MDN	3,64%	3,79%	3,59%	355,18	374,10	350,75
BJG	3,30%	3,36%	3,45%	547,82	573,28	583,79
MJK	4,43%	3,84%	3,85%	1449,45	1246,32	1251,39
PNG	3,78%	3,76%	3,76%	289,61	286,19	289,47
KDR	3,12%	3,36%	3,19%	584,75	665,73	597,14
PSR	7,36%	5,12%	8,20%	2311,36	1614,89	2459,50

Berdasarkan Tabel 4.35 dapat diketahui nilai kebaikan model SVR. Dua model ARIMA yang memenuhi asumsi parameter signifikan dari tiap kota akan digunakan sebagai input model SVR kota tersebut. Hasil dari model tersebut dinamai

dengan Model SVR1 dan Model SVR2. Sedangkan Model SVR3 merupakan model SVR yang menggunakan input model ARIMA yang memenuhi asumsi hingga white noise. Dari tabel 4.7 dapat diketahui bahwa model SVR1 memiliki nilai yang lebih kecil jika dibandingkan dengan SVR3. Sedangkan pada model SVR2, hanya terdapat dua kota yang nilai kebaikan modelnya lebih besar dibanding model SVR3, yaitu Madiun dan Kediri. Jadi dapat disimpulkan bahwa metode SVR akan menghasilkan nilai kebaikan model lebih tinggi jika menggunakan support vector dari metode ARIMA yang tidak harus memenuhi seluruh asumsinya.

4.4 Optimasi Parameter Model SVR dengan Menggunakan GA

Untuk mendapatkan nilai parameter yang optimal pada metode SVR tidak dapat dilakukan dengan mudah. Metode yang biasanya digunakan untuk mendapatkan metode yang optimum adalah dengan metode gridsearch. Pada penelitian ini juga akan dilakukan optimasi menggunakan Genetic Alghoritm untuk mendapatkan parameter yang optimum pada model SVR sehingga didapatkan nilai akurasi yang optimum. Seperti pada subbab sebelumnya pembahasan dan analisis dilakukan hanya kota Surabaya. Untuk kota dan kabupaten lain akan ditampilkan nilai akurasinya saja.

4.4.1 Optimasi Parameter Model SVR dengan Menggunakan GA untuk Kota Surabaya

Optimasi dengan menggunakan GA memiliki tujuh langkah utama yang harus dilakukan.

1. Yang pertama adalah mendefinisikan variabel-variabel yang diperlukan dalam optimasi GA. Variabel tersebut adalah

jumlah populasi, batas iterasi, peluang terjadi pindah silang, peluang terjadi mutasi dan kromosom untuk elitism. Jumlah populasi yang digunakan adalah sebanyak 100 kromosom dengan batas iterasi maksimum sebanyak 10 iterasi. Kemudian peluang untuk terjadi pindah silang adalah sebesar 0,8 dan peluang untuk terjadi mutase adalah sebesar 0,1. Kromosom yang terpilih dalam proses elitism sebanyak satu kromosom saja

2. Kemudian adalah melakukan inisialisasi kromosom. Pada penelitian ini melakukan optimasi pada parameter model SVR dengan fungsi kernel Gaussian (RBF) sehingga kromosom terbentuk dari vektor berukuran 3x1. Vektor tersebut akan diisi dengan nilai parameter dari SVR (cost,gamma,epsiloni). Nilai untuk pembentukan kromosom dapat diisikan dari hasil pemodelan SVR sebelumnya sebagai *Good Initial Value*.

<i>Cos</i>	<i>Gamma</i>	<i>Epsilon</i>	→	1,938114	0,02832872	0,1296242
------------	--------------	----------------	---	----------	------------	-----------


Gambar 4.76 Ilustrasi Bentuk Kromosom

Kemudian di generate sebanyak jumlah populasi sehingga terbentuk 100 kromosom dengan nilai parameter yang bervariasi didalamnya. Nilai kromosom di generate diantara nilai range dari parameter. Range parameter yang digunakan secara berturut-turut untuk cost, gamma dan epsilon adalah {(10-4:4),(10-4:1),(10-4:1)}.

3. Suatu kromosom baik atau tidak berdasarkan nilai dari fitness function. Fitness function yang digunakan adalah nilai dari SMAPE. Kromosom dapat dikatakan kromosom yang baik dan dapat bertahan hidup jika memiliki nilai

SMAPE yang kecil. Dari 100 kromosom yang telah di generate dihitung nilai SMAPE dari tiap kromosomnya.

4. Tiap kromosom kemudian akan diseleksi untuk dijadikan sebagai calon orang tua. Seleksi dilakukan dengan menggunakan roulette wheel. Nilai fitness yang didapatkan pada tahap sebelumnya digunakan panduan memilih calon orang tua. Nilai frekuensi adalah fitness kumulatif yang dibagi dengan total fitness. Nilai tersebut akan menjadi batas terpilihnya kromosom tersebut. Kromosom akan terpilih jika nilai dari bilangan random terletak pada range nilai frekuensi kromosom sebelumnya dan kromosom tersebut.
5. Kromsom yang sudah terpilih sebagai calon orang tua, di beri sebuah bilangan random uniform(0,1). Jika nilai bilangan tersebut kurang dari peluang terjadi pindah silang ($P_c = 0,8$) maka kromosom tersebut terpilih sebagai orang tua dan terjadi proses pindah silang.



Gambar 4.77 Ilustrasi Pindah Silang pada Kromosom

Kromsom 1 melakukan pertukaran isi (parameter) dengan kromosom 2. Sehingga menghasilkan kromomsom baru pada bagian kanan. Hasil kromosom baru tersebut juga dihitung nilai fitnessnya


6. Tahap keenam adalah melakukan mutasi pada kromosom yang terpilih. Mutasi dilakukan dengan mengubah salah satu nilai parameter dengan suatu bilangan random. Kromosom dipilih dengan cara memberikan bilangan random uniform(0,1) pada kromosom. Dan jika bilangan random tersebut bernilai lebih kecil dari peluang mutase ($P_m = 0,1$)

maka kromosom tersebut merupakan kromosom yang terpilih.

7. Tahap ketujuh adalah mengurutkan nilai fitness dari semua kromosom yang telah terbentuk, baik dari 100 kromosom awal, hasil pindah silang, dan mutasi dari paling kecil hingga paling besar. Satu kromosom dengan nilai fitness tertinggi akan disimpan dan pasti digunakan sebagai orang tua pada generasi selanjutnya. Selanjutnya adalah meng-generate populasi baru yang merupakan 100 kromosom dengan nilai fitness terendah. Kemudian dilakukan iterasi hingga iterasi ke 10.

Setelah dilakukan ketujuh tahap diatas maka dapat dihasilkan nilai ramalan yang dapat dibandingkan dengan data out-sample seperti berikut.

Dari Gambar 4.78 dapat diketahui pola hasil ramalan dari metode SVR-GA memiliki hasil yang baik karena pola dari hasil ramalan untuk data insample dan outsamplenya memiliki pola dan nilai yang mendekati. Nilai kebaikan model yang dihasilkan dari model SVR-GA adalah sebesar 3,557% untuk nilai SMAPE dan 3166,72 untuk nilai RMSE. Seperti halnya pemodelan SVR pada subbab sebelumnya, pemodelan SVR-GA juga dilakukan pada model ARIMA yang hanya memenuhi asumsi signifikan saja dan menghasilkan nilai kebaikan model sebagai berikut.



Gambar 4.78 Plot Hasil Ramalan SVR-GA dengan Data Outsampel Untuk Kota Surabaya

Tabel 4.36 Nilai Kebaikan Model untuk SVR-GA

Model	SMAPE	RMSE
ARIMA(1,1,0)(2,1,1) ¹⁴	3,15%	2734,03
ARIMA(1,1,1)(2,0,0) ¹⁴	3,16%	2651,54
ARIMA ([3,9],1,1)(1,0,1) ¹⁴	3,57%	3166,72

Tabel 4.36 merupakan nilai kebaikan model dari model SVR-GA. Pada baris satu dan dua merupakan model SVR-GA yang menggunakan model ARIMA yang memenuhi asumsi signifikan parameter sebagai inputnya. Karena model yang digunakan merupakan model yang sama pada SVR maka lag yang digunakan sebagai support vector sama dengan pada bagian SVR. Berdasarkan nilai kebaikan model pada tabel 4.8 dapat diketahui bahwa model SVR-GA, yang menggunakan input ARIMA yang memenuhi asumsi signifikan parameternya, memiliki nilai kebaikan model yang lebih baik jika dibandingkan dengan model SVR-GA yang menggunakan ARIMA yang memenuhi asumsi sebagai inputnya.

4.4.2 Optimasi Parameter Model SVR dengan Menggunakan GA untuk Kota Lainnya

Dengan langkah-langkah yang sama, pemodelan SVR-GA dapat dilakukan ke kota dan kabupaten lainnya. Model ARIMA dan lag yang digunakan sama dengan Model dan lag yang digunakan pada model SVR yang dapat dilihat pada Lampiran 3. Berikut merupakan nilai kebaikan model dari setiap kota dan kabupaten dengan menggunakan SVR-GA.

Tabel 4.37 Nilai Kebaikan Model SVR-GA untuk Setiap Kota Dan Kabupaten

KOTA	SMAPE			RMSE		
	SVRGA1	SVRGA2	SVRGA3	SVRGA1	SVRGA2	SVRGA3
SBY	3,15%	3,17%	3,56%	2734,02	2651,54	3166,72
MLG	2,77%	2,78%	2,95%	679,89	678,58	717,34
GSK	4,79%	5,00%	4,93%	860,86	911,82	889,92
SDA	6,70%	6,10%	6,70%	2088,43	1920,698	2081,6
PKS	4,59%	4,76%	4,70%	696,60	709,83	709,56
BWG	4,49%	4,89%	4,36%	418,50	447,12	395,79
JBR	3,94%	3,77%	3,84%	492,37	463,98	482,16
STB	3,65%	3,96%	3,90%	197,15	202,72	209,20
MDN	2,69%	2,79%	2,54%	284,33	286,85	261,27
BJG	2,78%	2,95%	2,92%	465,33	483,02	503,38
MJK	3,84%	3,77%	3,68%	1186,89	1191,42	1155,53
PNG	3,64%	3,53%	3,57%	276,82	272,65	273,69
KDR	2,54%	2,78%	2,64%	503,58	521,44	515,44
PSR	4,28%	4,32%	6,79%	1442,30	1390,26	2051,88

Tabel 4.37 merupakan daftar nilai kebaikan model SVR-GA untuk setiap kota dan kabupaten. Seperti halnya pada metode SVR, model SVR-GA dilakukan pemodelan menggunakan input lag dari dua model ARIMA yang hanya memenuhi asumsi parameter

signifikan. Kedua model tersebut dinamai dengan SVRGA1 dan SVRGA2. Sedangkan SVRGA3 merupakan model SVR-GA yang menggunakan input ARIMA yang memenuhi asumsi. Dari tabel 4.9 dapat diketahui bahwa hasil akurasi untuk model SVRGA1 dan SVRGA2 bernilai lebih kecil daripada model SVRGA3. Jadi dapat disimpulkan bahwa pemodelan SVR-GA menggunakan input ARIMA yang tidak memenuhi semua asumsi, menghasilkan nilai akurasi yang lebih baik jika dibandingkan dengan menggunakan ARIMA yang memenuhi asumsinya.

4.5 Optimasi Parameter Model SVR dengan Menggunakan PSO

Sama halnya dengan *Genetic Algorithm*, *Particle Swarm Optimization* digunakan untuk mempermudah mendapatkan nilai parameter model SVR yang optimum. Analisis dan pembahasan juga akan dilakukan untuk kota Surabaya sebagai kota dengan permintaan beban tertinggi dan kota lainnya akan ditampilkan model dan nilai kebaikan modelnya.

4.5.1 Optimasi Parameter Model SVR dengan Menggunakan PSO untuk Kota Surabaya

Optimasi dengan menggunakan PSO memiliki lima langkah utama yang harus dilakukan.

1. Mendefinisikan parameter-parameter yang digunakan dalam PSO, yaitu jumlah partikel, batas iterasi maksimum, bobot inersia, batas maksimum kecepatan, koefisien komponen tiap partikel (C_1) dan koefisien komponen semua partikel (C_2). Jumlah partikel yang digunakan adalah 100 partikel dengan batas iterasi maksimum adalah 100 kali iterasi. Bobot inersia (w) bernilai 0,9 dan Batasan

- kecepatan maksimum 1. C_1 dan C_2 bernilai sama dengan 0,2.
2. Menginisialisasikan vektor posisi dari tiap partikel. Dimensi dari partikel PSO ditentukan dari jumlah parameter yang akan dioptimasi. Pada penelitian ini parameter yang akan dioptimasi adalah parameter dari Model SVR dengan fungsi kernel *Gaussian* (RBF), yaitu *cost*, *gamma* dan *epsilon*. Jadi vektor posisi terbentuk dalam ukuran 3x1, karena terdapat tiga parameter yang akan dioptimasi. Posisi parameter akan di *generate* secara random diantara *range* parameter yang digunakan. *Range* parameter yang digunakan berturut-turut untuk parameter *cost*, *gamma* dan *epsilon* adalah $\{(10^{-4}:4), (10^{-4}:1), (10^{-4}:1)\}$.
 3. Menentukan *fitness function* yang merupakan kandungan jumlah makanan. *Fitness function* yang digunakan adalah menggunakan SMAPE. Dari 100 vektor posisi dihitung nilai fitnessnya dan kemudian diurutkan dari nilai paling kecil hingga paling besar.
 4. Langkah selanjutnya adalah melakukan pergeseran partikel dengan menggunakan rumus berikut

$$x_i(t+1) = x_i(t) + v_i(t+1)$$

Vektor posisi suatu partikel akan ditambah dengan vektor kecepatan dan menjadi sebuah posisi baru. Vektor kecepatan tersebut dihitung dengan menggunakan rumus berikut.


$$v_i(t) = v_i(t-1) + c_1 r_1 (localbest(t) - x_i(t-1)) + c_2 r_2 (globalbest(t) - x_i(t-1))$$

Dimana local best merupakan nilai *fitness* terbaik dari suatu partikel dan *global best* merupakan nilai *fitness* terbaik dari keseluruhan partikel. Setelah dilakukan

pergeseran, selanjutnya dihitung nilai *fitness* dari posisi partikel yang baru.

5. Kemudian langkah 1 hingga 4 diulang hingga mencapai batas iterasi atau setelah semua partikel menghasilkan *fitness* yang konvergen.

Setelah didapatkan hasil yang konvergen maka dapat dilakukan peramalan dan kemudian dibandingkan dengan data *outsample*. Berikut merupakan perbandingan antara hasil ramalan SVR-PSO dengan data *outsample*.



Gambar 4.79 Perbandingan Hasil Ramalan SVR-PSO dengan Data *Outsample*

Dari Gambar 4.68 dapat diketahui pola ramalan dari SVR-PSO merupakan pola ramalan yang baik. Hal tersebut ditandai dengan pola dan nilai hasil ramalan mendekati data asli. Nilai akurasi yang dihasilkan dari model SVR-PSO adalah sebesar 3,779% untuk nilai SMAPE dan 3062,709 untuk nilai RMSE. Sama halnya dengan SVR dan SVR-GA, pemodelan SVR-PSO diatas menggunakan ARIMA yang memenuhi asumsi sebagai pembentuk *support vector*. Pemodelan SVR-PSO juga akan dilakukan pada model ARIMA yang hanya memenuhi asumsi signifikan parameter saja. Nilai hasil dari kebaikan modelnya adalah sebagai berikut.

Tabel 4.38 Nilai Kebaikan Model SVR-PSO untuk Kota Surabaya

Model	SMAPE	RMSE
ARIMA(1,1,0)(2,1,1) ¹⁴	4.93%	3989.69
ARIMA(1,1,1)(2,0,0) ¹⁴	4.64%	3912.20
ARIMA ([3,9],1,1)(1,0,1) ¹⁴	3,78%	3062,71

Dari Tabel 4.38 dapat diketahui kebaikan model dari SVR-PSO untuk kota Surabaya. Pada baris pertama dan kedua merupakan peramalan dengan menggunakan SVR-PSO dimana *support vector* dibentuk dari lag yang signifikan Model ARIMA yang hanya memenuhi asumsi signifikan parameter. Model ARIMA yang digunakan sama dengan pada peramalan dengan menggunakan SVR dan SVR-GA, maka nilai lag yang digunakan bernilai sama yang dapat dilihat pada bagian SVR. Dari Tabel 4.9 dapat diketahui bahwa model SVR-PSO dengan input ARIMA yang hanya memenuhi asumsi signifikan parameter tidak bernilai lebih baik dari model yang menggunakan ARIMA yang memenuhi asumsi.

4.5.1 Optimasi Parameter Model SVR dengan Menggunakan PSO untuk Kota Lainnya

Dengan langkah-langkah yang telah dijelaskan pada subbab sebelumnya, dapat dilakukan pemodelan dan peramalan untuk kota dan kabupaten lainnya. Model ARIMA dan lag yang digunakan sama dengan model SVR. Model ARIMA dan lag yang signifikan dapat dilihat pada Lampiran 3. Berikut merupakan nilai dari kebaikan model untuk Pemodelan SVR-PSO di setiap kota dan kabupaten.

Tabel 4.39 Nilai Keباikan Model SVR-PSO untuk Setiap Kota dan Kabupaten

KOTA	SMAPE			RMSE		
	SVRPSO1	SVRPSO2	SVRPSO3	SVRPSO1	SVRPSO2	SVRPSO3
SBY	4,93%	4,64%	3,78%	3989,69	3912,20	3062,71
MLG	3,23%	4,55%	3,32%	763,54	1051,87	773,24
GSK	5,37%	4,88%	5,37%	955,85	875,06	955,85
SDA	7,28%	7,28%	7,33%	2237,30	2237,30	2256,50
PKS	5,91%	6,03%	5,91%	780,79	820,54	780,75
BWG	4,92%	5,45%	10,33%	463,94	523,24	934,23
JBR	5,10%	5,10%	4,17%	644,68	644,74	519,12
STB	4,30%	3,81%	4,17%	220,76	201,83	216,18
MDN	4,05%	2,92%	2,88%	393,04	303,73	293,52
BJG	3,19%	3,18%	3,56%	541,65	517,34	559,11
MJK	6,34%	5,25%	6,34%	2071,03	1672,77	2070,34
PNG	3,93%	3,87%	3,63%	298,83	282,10	285,20
KDR	3,81%	2,91%	3,20%	718,49	561,04	587,12
PSR	7,12%	5,64%	4,65%	2158,70	1898,63	1487,80

Dari Tabel 4.39 dapat diketahui bahwa nilai kebaikan model dari SVR-PSO untuk setiap kota dan kabupetennya. SVRPSO1 dan SVRPSO2 merupakan model pemodelan SVR-PSO yang menggunakan ARIMA dengan asumsi signifikan parameter sebagai inputnya. Sedangkan SVRPSO3 menggunakan ARIMA yang memenuhi asumsi. Berbeda dengan SVR dan SVR-GA, nilai yang dihasilkan bervariasi. Untuk beberapa kota, Model SVRPSO1 dan SVRPSO2 memiliki akurasi lebih tinggi, di kota lainnya kebalikannya.

4.6 Perbandingan Akurasi dari Setiap Model Pemodelan

Setelah didapatkan hasil ramalan dan nilai kebaikan model dari setiap metode, maka langkah selanjutnya adalah membandingkan nilai kebaikan model antar metode yang dapat dilihat dalam tabel berikut.

Dari Tabel 4.39 dapat diketahui terdapat beberapa variasi metode yang lebih unggul dengan hasil ramalan yang lebih tinggi. Setiap metode yang memiliki nilai smape lebih dari satu, telah ditandai nilai terbaik dari metode tersebut dengan diberi warna tebal pada nilai SMAPEnya. Dan jika diperhatikan dan diberi ranking tiap metode maka dapat terbentuk urutan sebagai berikut

Tabel 4.40 Tabel Perbandingan Akurasi Untuk Setiap Metode di Setiap Kota

KOTA	ARIMA	SVR1	SVR2	SVR3	SVRGA1	SVRGA2	SVRGA3	SVRPSO1	SVRPSO2	SVRPSO3
SBY	35%	4%	5%	5%	3%	3%	4%	5%	5%	4%
MLG	13%	3%	3%	4%	3%	3%	3%	3%	5%	3%
GSK	24%	6%	6%	6%	5%	5%	5%	5%	5%	5%
SDA	51%	10%	7%	10%	7%	6%	7%	7%	7%	7%
PKS	14%	5%	5%	5%	5%	5%	5%	6%	6%	6%
BWG	5%	6%	6%	6%	4%	5%	4%	5%	5%	10%
JBR	5%	5%	5%	5%	4%	4%	4%	5%	5%	4%
STB	5%	4%	4%	4%	4%	4%	4%	4%	4%	4%
MDN	8%	4%	4%	4%	3%	3%	3%	4%	3%	3%
BJG	4%	3%	3%	3%	3%	3%	3%	3%	3%	4%
MJK	54%	4%	4%	4%	4%	4%	4%	6%	5%	6%
PNG	10%	4%	4%	4%	4%	4%	4%	4%	4%	4%
KDR	15%	3%	3%	3%	3%	3%	3%	4%	3%	3%
PSR	49%	7%	5%	8%	4%	4%	7%	7%	6%	5%

. Tabel 4.40 merupakan tabel urutan dari keempat metode yang telah digunakan. Urutan tersebut disusun dari nilai sMAPE yang paling kecil dari semua metode yang digunakan dalam penelitian ini. Dari Tabel 4.40 dapat diketahui bahwa posisi SVR-GA selalu berada pada posisi pertama, maka dapat disimpulkan metode optimasi GA lebih baik dibandingkan dengan metode optimasi PSO pada penelitian ini. Dan untuk beberap kota nilai

optimasi oleh PSO, tidak lebih baik daripada metode pemodelan SVR itu sendiri. Pada beberapa kota, seperti Banyuwangi dan Jember, kebaikan model untuk metode ARIMA memiliki hasil yang lebih baik dibandingkan dengan SVR. Hal tersebut diduga karena adanya pola linier sehingga ARIMA dapat menghasilkan nilai ramalan pada data outsampel lebih baik.

Tabel 4.41 Urutan Metode Berdasrakan Nilai sMAPE dari 14 Kota

Kota	Urutan			
	I	II	III	IV
SBY	SVR-GA	SVR-PSO	SVR	ARIMA
MLG	SVR-GA	SVR	SVR-PSO	ARIMA
GSK	SVR-GA	SVR-PSO	SVR	ARIMA
SDA	SVR-GA	SVR	SVR-PSO	ARIMA
PKS	SVR-GA	SVR	SVR-PSO	ARIMA
BWG	SVR-GA	SVR-PSO	ARIMA	SVR
JBR	SVR-GA	SVR-PSO	ARIMA	SVR
STB	SVR-GA	SVR-PSO	SVR	ARIMA
MDN	SVR-GA	SVR-PSO	SVR	ARIMA
BJG	SVR-GA	SVR-PSO	SVR	ARIMA
MJK	SVR-GA	SVR	SVR-PSO	ARIMA
PNG	SVR-GA	SVR-PSO	SVR	ARIMA
KDR	SVR-GA	SVR-PSO	SVR	ARIMA
PSR	SVR-GA	SVR-PSO	SVR	ARIMA

BAB V

KESIMPULAN DAN SARAN

. 5.1 Kesimpulan

Setelah dilakukan analisis dan juga pembahasan pada Bab IV, berikut merupakan kesimpulan-kesimpulan yang dapat diambil dari penelitian ini yang berkaitan dengan latar belakang dan tujuan penelitian.

1. a. Dari 14 kota, Kota Surabaya merupakan kota dengan rata-rata permintaan beban terbesar diantara kota lainnya. Rata-rata besar permintaannya mencapai hampir dua kali dari rata-rata permintaan dari kota lain. Permintaan terendah dari kota Surabaya lebih tinggi dibandingkan dengan permintaan tertinggi dari 5 kota lain.
- b. Beberapa pola musiman muncul dalam permintaan beban listrik di setiap kota. Pola mingguan merupakan pola musiman yang paling banyak muncul, karena setelah ditampilkan dalam *time series plot* beberapa kota memiliki permintaa yang lebih rendah pada hari Minggu. Pola musiman siang malam tidak terlalu banyak berpengaruh pada beberapa kota besar.
2. a. Peramalan dengan menggunakan metode ARIMA tidak dapat menghasilkan peramalan yang memmenuhi asumsi reisudal berdistribusi normal. Hasil ramalan di beberapa kota tidak terlalu baik karena terdapat pola menjauhi data outsampel.
- b. Peramalan SVR menghasilkan ramalan yang lebih baik jika dibandingkan dengan metode ARIMA. Terdapat 12 Model peramalan SVR yang memiliki nilai sMAPE lebih rendah dibandingkan dengan hasil ramalan dari ARIMA. ARIMA hanya unggul pada ramalan di kota Jember dan Banyuwangi.

- c Metode optimasi GA memiliki hasil optimasi yang lebih baik karena hasil nilai kebaikan model selalu menjadi peringkat pertama dari setiap model peramalan. PSO terdapat pada peringkat kedua setelah GA. Pada beberapa kota, PSO menghasilkan hasil peramalan yang lebih jelek dibandingkan dengan SVR, yaitu di kota MLG, SDA, PKS. Dan MJK.

5.2 Saran

Berdasarkan hasil analisis yang telah dilakukan, maka rekomendasi bagi PT PLN (Persero) di wilayah Jawa Timur dalam meramalkan pemakaian beban listrik sebaiknya menggunakan metode *Support Vector Regression* yang dioptimasi dengan menggunakan *Genetic Alghorithm* dan menggunakan input dari lag yang telah signifikan dari model ARIMA.

Selain itu, penelitian ini tentunya memiliki beberapa kekurangan sehingga saran untuk penelitian selanjutnya yaitu sebagai berikut.

1. Perlu dilakukan pemodelan ARIMA hingga menemukan model yang memenuhi semua asumsi sehingga bisa dibandingkan dengan jelas kebaikan model antara SVR dan ARIMA.
2. Pada GA dan PSO hanya menggunakan 1 kombinasi *range* parameter. Pada penelitian selanjutnya bisa dibandingkan antara kedua metode dengan kombinasi *range* parameter yang lebih bervariasi.

DAFTAR PUSTAKA

- Adhi, Irawan Sapto. (2015). *PLN Pasang Trafo Baru, Aliran Listrik 3 Kecamatan di Ngawi Padam*. Solopos. Retrieved Januari 13, 2017, from Web site : <http://www.solopos.com/2015/11/25/pemadaman-listrik-ngawi-pln-pasang-trafo-baru-aliran-listrik-3-kecamatan-di-ngawi-padam-664506>
- Box, G., & Cox, D. R. (1964). An Analysis of Transformations. *Journal of The Royal Statistical Society, Series B (Methodological)*, 211-252.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis With Application in R*. New York: Springer Science.
- Duan, K., Keerthi, S. S., & Poo, A. N. (2003). Evaluation of simple performance measures for. *Neurocomputing*, 41-59.
- Ehab, E. E., Goulermas, J., & Wu, Q. H. (2010). Electric Load Forecasting Based on Locally Weighted Support Vector Regression. *IEEE*.
- Ghalia, M. B. (2008). Particle Swarm Optimization with an Improved Exploration-Exploitation Balance. *IEEE*.
- Gunn, S. R. (1998). *Support Vector Machine for Classification and Regression*. Southampton: University of Southampton.
- Gupta, A., & Pradepta, K. (2012). Electrical Load Forecasting Using Genetic Alghoritm Based Back-Propagation Method. *ARNP Journal of Engineering and Applied Sciences*.
- Handayani, D. Y. (2014). *Ribuan Industri Jatim Terancam Krisis Listrik*. Retrieved Desember 19, 2016. Web Site :

- <http://www.suarasurabaya.net/fokus/190/2014/133435-Ribuan-Industri-Jatim-Terancam-Krisis-Listrik>
- Hong, W. (2011). Forecasting Urban Traffic Flow by SVR with Continuous ACO. *Applied Mah*, 1282-1291.
- Ismail, Z., & Irhamah. (2008). Solving the Vehicle Routing Problem with Stochastic Demands via. *Journal of Mathematics and Statistics*, 161-167.
- Jadaan, O. A., Rajamani, L., & Rao, C. R. (2005-2008). Improved Selection Operator for GA. *GA. Journal of Theoretical and Applied Information Technology (JATIT)*, 269-277.
- Khair, A. (2011). *Peramalan Beban Listrik Jangka Pendek Menggunakan Kombinasi Autoregressive Integrated Moving Average (ARIMA) dengan Regresi Linear antara Suhu dan Daya Listrik*. Jakarta: Universitas Indonesia.
- Kusumaningrum, Pramita. (2016). *PLTU Pacitan Gangguan, Madiun Raya, Kediri, Trenggalek Gelap Gulita*. Retrieved Desember 30, 2016, from Berita Jatim Web site : http://beritajatim.com/peristiwa/283515/pltu_pacitan_gangguan,_madiun_raya,_kediri,trenggalek_gelap_gulita.html
- Kusumawati, Y., Irhamah, & Soedjono, S. E. (2014). *Pemodelan Faktor-Faktor yang Mempengaruhi Rumah Tangga Membuang Limbah Domestik Blackwater di Surabaya Timur dengan Regresi Logistik dan Algoritma Genetika*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Nurmahaluddin. (2014). Perbandingan Algoritma Particle Swarm Optimization dan Regresi pada Peramalan Waktu Beban Puncak. *Jurnal POROS TEKNIK, Volume 6, No. 2*.
- Ouarda, A., & Bouamar, M. (2014). A Comparison of Evolutionary Algorithms: PSO, DE and GA for Fuzzy C-

- Partition. *International Journal of Computer Applications*.
- Paramita, N. L., & Irhamah. (2012). *Peramalan Beban Listrik Menggunakan Genetic Alghoritm - Support Vector Machine (GA-SVM) di PT PLN (Persero) SUB Unit Penyaluran dan Pusat Pengaturan Beban (P3B) Jawa Timur - Bali*. Surabaya: Institut Teknologi Sepuluh Nopember.
- PLN Distribusi Jawa Timur. (2013). *Laporan Statistik*. Surabaya.
- Prasetyo, E. (2014). *Data Mining Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: Graha Ilmu.
- Radar Madiun. (2016). *Ujian Dihantui Listrik Mati*. Retrieved Januari 10, 2017, from Radar Madiun Web site : <https://radarmadiun.co.id/detail-berita-1356-ujian-dihantui-listrik-mati--.html>
- Suyanto. (2005). *Algoritma Genetika dalam MATLAB (Genetic Algorithm in MATLAB)*. Yogyakarta: Andi Publisher.
- Tempo. (2016). *Kebutuhan Listrik Jatim Mencapai 5.700 Megawatt*. Jawa Timur, Indonesia. Retrieved from Tempo.co.
- Trapsilasiwi, R. K., & Sutijo, B. (2011). *Peramalan Beban Listrik Jangka Pendek Menggunakan Hybrid Improved Particle Swarm Optimization - Support Vector Machine di PLN Region Jawa Timur - Bali*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods, 2nd ed*. New York: Pearson.
- Zhai, Y. (2005). *Time Series Forecasting Competition Among Three Sophisticated Paradigms*. Wilmington: University of North Carolina Wilmington.

(Halaman Sengaja Dikosongkan)

LAMPIRAN

Lampiran 1. Surat Legalitas Data

SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Departemen Statistika FMIPA-ITS dengan identitas berikut :

Nama : Adam Surya Wijaya
NRP : 13 13 100 082

Telah mengambil data di instansi/perusahaan kami

Nama Instansi : PT PLN (PERSERO) DISTRIBUSI JATIM
Divisi/bagian : DISTRIBUSI

Sejak tanggal 1 Januari 2016 sampai dengan 28 Februari 2017
untuk keperluan Tugas Akhir Semester genap 2016/2017

2. Tidak Keberatan / ~~Keberatan~~ nama perusahaan dicantumkan dalam Tugas Akhir mahasiswa Statistika yang akan disimpan di perpustakaan ITS dan dibaca di lingkungan ITS.
3. Tidak Keberatan / ~~Keberatan~~ bahwa hasil analisis data dari perusahaan dipublikasikan dalam E-journal ITS yaitu Jurnal Sains dan Seni ITS.

Surabaya, 8 Juni 2017.....

Assistant Analyst Pengembangan
Kompetensi



Adam
Fara Sofah Intani

Lampiran 2. Syntax untuk Pemodelan ARIMA

```
data wisman;
input x;
datalines;
12.9950
18.3990
14.1410
18.9280
.
.
.
16.2060
19.5490
14.4790
18.5530
;
proc arima data=wisman;
identify var = x(1,14);
run;
estimate q=(14) p=(1,2,3,4,3,5,2) noconstant method=cls;
forecast out= ramalan lead=118;
run;
outlier maxnum=5 alpha=0.05;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=work.ramalan
outfile="d:\ramalan.xls"
dbms=excel97
replace;
sheet="2";
run;
```

Lampiran 3. Syntax untuk Pemodelan SVR

```
library(e1071)
library(tseries)
data=read.csv("D:/INPUT2-SVRb-PSR.csv",sep="," ,header=T)
train=data[1:703,]
test=data[-c(1:703),]
tuneResult=tune(svm, yt ~.,data=train,kernel="radial",ranges =
list(epsilon = seq(1e-4,1), cost =seq(1e-4,10),gamma=seq(1e-
4,4)))
tunedmodel=tuneResult$best.model;tunedmodel
forecast=predict(tunedmodel,test)
prediksiSVR=predict(tunedmodel,train_data)

forecast=((forecast))
zt=((test[,1]))
isi=zt-forecast
rmse=sqrt(mean(isi^2))
mape=sum((zt-forecast)/zt)/length(zt)
smape=sum(abs(zt-
forecast)/((abs(zt)+abs(forecast))/2))/length(zt)
rmse
smape

write.table(forecast,"D:/outTA-SVR2B-PSR.txt")
write.table(prediksiSVR,"D://inTA-SVR2B-PSR.txt")
```

Lampiran 4. Syntax untuk Pemodelan SVR-GA

```

rm(list=ls())
library(e1071)
library(GA)

d=read.csv("D:/INPUT2-SVRb-PSR.csv",sep="," ,header=T)
trngdata = d[1:703,]
tmngdata = d[-c(1:703),]
# Fitness function (to be maximized)
# Parameter vector x is: (cost, gamma, epsilon)
fitnessFunc<- function(x) {
  # Retrieve the SVM parameters
  cost <- x[1]
  gamma <- x[2]
  epsilon <- x[3]
  # Train
  model <- svm(yt ~ ., data = trngdata, cost = cost, gamma = gamma, epsilon =
epsilon, type = "eps-regression", kernel = "radial")
  # Test
  smape<- mean(abs((predict(model, newdata = trngdata) -
trngdata$yt)/((abs(predict(model, newdata = trngdata))+abs(trngdata$yt))/2)))
  return(-smape)
}

# Range of the parameter values to be tested
# Parameters are: (cost, gamma, epsilon)
theta_min<- c(cost = 1e-3, gamma = 1e-3, epsilon = 1e-6)
theta_max<- c(cost = 4, gamma = 1, epsilon = 1)

# Run the genetic algorithm
results <- ga(type = "real-valued", fitness = fitnessFunc,
  names = names(theta_min),
  min = theta_min, max = theta_max,
  popSize = 100, maxiter = 10,monitor=plot)

hasil=summary(results)
hasil
modpred=svm(yt~.,data=trng_data,cost=
hasil$solution[1],gamma=hasil$solution[2],epsilon=hasil$solution[3])
prediksiGA=predict(modpred,trngdata)
predGA=predict(modpred,tmngdata)
zt=tn_data[,1]
rmse= (mean((zt-predGA)^2))^(1/2); rmse
smape=mean(abs(zt-predGA)/((abs(zt)+abs(predGA))/2)); smape

write.table(predGA,"D://outTA-SVRGA2B-PSR.txt")
write.table(prediksiGA,"D://inTA-SVRGA2B-PSR.txt")

```

Lampiran 5. Syntax untuk Pemodelan SVR-PSO

```

rm(list=ls())
library(e1071)
library(foreign)
library(psoptim)
d=read.csv("D:/INPUT2-SVRb-PSR.csv",sep="," ,header=trdataUE)
trngdata = d[1:703,]
tmgdata = d[-c(1:703),]
# Fitness function (to be maximized)
# Parametndatar vector x is: (cost, gamma, epsilon)
fitnessFunc<- function(x) {
  # Retrdataieve the SVM parametndatars
  cost <- x[1]
  gamma <- x[2]
  epsilon <- x[3]
  # trdataain
  model <- svm(yt ~ ., data = trngdata, cost = cost, gamma = gamma,
epsilon = epsilon, type = "eps-regression", kernel = "radial")
  # tndatast
  smape<- mean(abs((predict(model, newdata = trngdata) -
trngdata$yt)/((abs(predict(model, newdata =
trngdata))+abs(trngdata$yt))/2)))
  return(-smape)
}
# Range of the parametndatar values to be tndatastndatad
# Parametndatars are: (cost, gamma, epsilon)
theta_min<- c(cost = 1e-3, gamma = 1e-3, epsilon = 1e-6)
theta_max<- c(cost = 1, gamma = 1, epsilon = 1)
# Run the genetic algorithm
results <- psoptim(FUN=fitnessFunc, n=100, max.loop=100, w=0.9,
c1=0.2, c2=0.2,
xmin=theta_min, xmax=theta_max, vmax=c(1,1,1), seed=100, anim=T)
results
modpred=svm(yt~.,data=trdata,cost=
results$sol[1],gamma=results$sol[2],epsilon=results$sol[3])
prediksiPSO=predict(modpred,trngdata)
predPSO=predict(modpred,tmgdata)
zt=tndata[,1]
rmse=(mean((zt-predPSO)^2))^(1/2); rmse
smape=mean(abs(zt-predPSO)/((abs(zt)+abs(predPSO))/2)); smape
writndata.table(prediksiPSO,"D://inTA-SVRPSO2B-PSR.txt")
writndata.table(predPSO,"D://outTA-SVRPSO2B-PSR.txt")

```

Lampiran 6. Syntax untuk Pengujian Nonlinearitas
Terasvirta

```
library(tseries)
datain = read.csv("d:/insample.csv",header=T,sep=",")
nlag=14
pvall=array(0,c(14,nlag))
kes=array(0,c(14,nlag))
p=ncol(datain)-2
for ( i in 1:p)
{
  x=as.ts(datain[,i])
  for (j in 1 : nlag)
  {
    y=terasvirta.test(x,lag=j)
    pvall[i,j]=y$p.value
    if (y$p.value<0.05)
      kes[i,j]=1
    else
      kes[i,j]=0
  }
}
pvall
kes
```


BIODATA PENULIS



Penulis memiliki nama lengkap Adam Surya Wijaya, sering dipanggil dengan nama Adam. Penulis Lahir di Madiun pada tanggal 29 April 1996. Penulis merupakan anak pertama, dari dua bersaudara dan dari pasangan Edy Wijanto dan Maria Kusumawati. Penulis menempuh masa SD dan SMP di SDK dan SMPK Santo Yusuf Madiun. Setelah itu melanjutkan jenjang SMA di SMA Negeri 1 Madiun dan kemudian pada tahun 2013 lolos tes tulis SBMPTN ke Jurusan Statistika ITS. Selama 8 semester kuliah di Statistika ITS, aktif mengikuti kegiatan melalui organisasi SCC HIMASTA-ITS kepengurusan 14/15 dan 15/16. Selama di SCC pernah menjabat sebagai Manager Training Development SCC- HIMASTA ITS 15/16. Segala kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir dapat dikirimkan melalui e-mail ke alamat adam.sw.yume99@gmail.com.